

論文目録

様式 6

報告番号	甲工 乙工第24号 工修	氏名	竹田史章
学位論文題目	知的情報処理応用による貨幣識別技術に関する研究		
論文の目次			
第1章 はじめに			
第2章 紙幣識別の識別式決定に対するエキスパートシステム			
第3章 FFTを前処理とするニューラルネットワークによる紙幣識別			
第4章 ニューラルネットワークを用いた高速搬送紙幣の識別			
第5章 ランダムマスクによるニューラルネットワークの規模の縮小化と紙幣識別への応用			
第6章 ランダムマスク方式によるニューロ紙幣識別機の開発			
第7章 おわりに			
参考文献			
関連発表論文			
謝辞			
参考論文			
別紙のとおり			

備考

- 論文題目は、用語が英語以外の外国語のときは日本語訳をつけて、外国語、日本語の順に列記すること。
- 参考論文は、論文題目、著者名、刊行の方法及び時期を順に明記すること。
- 参考論文は、博士論文の場合に記載すること。

主論文

NO	論文題目	著者名	公刊機関名	公刊時期
1	紙幣識別の識別式決定に対するエキスパートシステム	竹田史章 大松 繁 井上 卓	情報処理学会 論文誌 第33巻第7号 pp. 980-991	平成4年 7月
2	フーリエ変換を前処理とするニューラルネットワークによる紙幣識別	竹田史章 大松 繁 井上 卓 尾波幸三	システム制御 情報学会 論文誌 第5巻第7号 pp. 265-273	平成4年 7月
3	ニューラルネットワークを用いた高速搬送紙幣の識別	竹田史章 大松 繁 井上 卓 尾波幸三 小西健一	電気学会 論文誌 C 第112巻第4号 pp. 249-258	平成4年 4月
4	ランダムマスクを前処理機構に有する小規模ニューラルネットワークによる貨幣識別技術	竹田史章 大松 繁	電気学会 論文誌 C 第113巻第10号	平成6年 1月
5	Bill Money Recognition Using a Small Size Neural Network	F. Takeda S. Omatu	Progress in Neural Network in Japan Special Volume	1994
6	High Speed Bill Money Recognition by Neural Networks	F. Takeda S. Omatu	IEEE Transactions on Neural Networks (掲載予定)	
7	マスク方式によるニューロ紙幣識別機の開発	竹田史章 大松 繁	システム制御情報 学会誌 第6巻第6号 pp. 283-289	平成5年 6月

副論文

NO	論文題目	著者名	公刊機関名	公刊時期
8	A Structre Reduction of Neural Network with Random Masks and Bill Money Recognition	F.Takeda S.Omatu T.Inoue S.Onami	The 2nd Internal Conference on Fuzzy Logic and Neural Networks IIZUKA '92 Vol. 2, pp. 809-813	1992. 6
9	High Speed Conveyed Bill Money Recognition with Neural Network	F.Takeda S.Omatu T.Inoue S.Onami	IMACS/SICE International Symposium on Robotics Mecha-tronics and Manufacturing Systems '92 Kobe Vol. 1, pp. 16-20	1992. 9
10	Bill Money Recognition by a Small Size Neural Network	F.Takeda S.Omatu	Bulletin of Faculty of Engineering, Tokushima University, No. 38, pp. 113-121	1993. 3
11	Bank Note Recognition System Using Neural Network with Random Masks	F.Takeda S.Omatu	World Congress on Neural Net-works, Portland, USA, Vol1, pp. 241-244	1993. 7
12	Recognition System of US Dollars Using a Neural Network with Random Masks	F.Takeda S.Omatu	International Joint Conference on Neural Net-works, Nagoya, Vol. 2, pp. 2033-2036	1993. 10

論文内容要旨

様式7

報告番号	甲工 乙工第24号 工修	氏名	竹田史章
学位論文題目	知的情報処理応用による貨幣識別技術に関する研究		
内容要旨 本論文は、貨幣識別という首尾一貫したテーマの下に論旨を展開するものである。一般に、紙幣識別機は市場ニーズとして、一秒間に10枚以上の紙幣を識別する能力、さらに、製品としてはハードウェアの低コスト化と装置のコンパクト性が要求されている。したがって、製品化においてはアルゴリズムそのものを演算量の少ない単純なものにすることが必要である。それゆえ、紙幣識別機開発の分野では以前から独自の識別式が考案され、この方式による製品化が行われてきた。この識別式は基本的に加算、減算、比較の各演算子を用いて紙幣の特徴を表現したものである。しかしながら、識別式を構成するパラメータに関しては、金種の違い、データ採取時の紙幣の回転、位置ずれ、起伏によるデータ変動を想定して、設計者が決定している。このような方法ではパラメータの組合せ数が非常に多く、得られた組合せが最適であるか否かの保証はなされていない。そこで、設計目標に到達したか否かを大量の紙幣データを用いて実験的に検証し、多大な工数を要して識別機の開発が行われている。また、設計者のノウハウおよび経験である紙幣識別に関する知識は、個々の単発的な処理手続きであり、パラメータ決定を行う際には一貫した処理フローを作成するのが困難である。このような専門家の試行錯誤の分野に知的情報処理手法の一つとして、我々は、まずエキスパートシステム（以後ESと略記する）を導入する。ここでは、紙幣識別の分離関数である識別式決定に対するESの構築について述べる。つぎに、ESを識別技術に導入することにより、従来技術と比較して大幅に開発期間および識別性能の向上が得られることを示す。しかしながら、ここでのESの効果は、紙幣の識別式決定においてのみ有効であり、紙幣識別における分離関数方式の問題点（市場における紙幣に対する汚れ、破れなどのノイズ、さらにはセンサ系に対する信号ノイズなどのロバスト性の問題）を解決するに至っていない。一方、本研究では紙幣識別分野への知的情報処理の別のアプローチとして、ニューラルネットワーク（以後NNと略記する）を検討する。以後では、このNNを応用した紙幣識別手法について考察する。ここでは、紙幣識別に適したNNの構成ならびに入力情報の検討をフーリエ変換などを利用して行う。また、紙幣識別の分野で従来から			

問題となっていた識別結果に対する信頼性に対して、新たに信頼性評価規範を導入し、潜在的な識別性能を検討する。NNを応用した紙幣識別手法が、識別性能と開発期間の点から、従来の分離関数方式や一部のパターンマッチング方式と比較して非常に有効な手法であることを述べる。しかるに、これらの種々の検討結果を基に、NNを実際の8あるいは16ビットのCPUを有する識別機に移植する場合、ネットワークの規模が大きな問題となる。そこで本研究では、入力画像の一部を任意に被覆するランダムマスクを提案する。ここでは、このランダムマスクによるNNの規模の縮小化について述べ、本提案手法により入力画像情報を容易に圧縮することが可能であることを示す。さらに、従来のNNを用いた手法と比較して、提案手法が識別性能の劣化を最小限にとどめ、大幅なネットワークの規模の縮小化を可能とすることを定量的に示す。また、提案手法により特殊なデバイスを用いなくても実システムが容易に構築可能であることを既存の識別機とパーソナルコンピュータを用いて具体的に示す。

最後に、実験システムにより、日本、韓国、米国の複数国紙幣が混合した場合の紙幣識別が可能であることを実験的に検証する。

知的情報処理応用による
貨幣識別技術に関する研究

平成 6 年 3 月

竹 田 史 章

知的情報処理応用による貨幣識別技術に関する研究 平成 6 年 3 月 竹田史章

目 次

第1章 はじめに	1
第2章 紙幣識別の識別式決定に対するエキスパートシステム	3
2.1 はじめに	3
2.2 従来の識別式決定手法	4
2.2.1 特徴抽出関数	5
2.2.2 識別式	6
2.2.3 識別式群決定の評価	6
2.2.3.1 鑑別率	6
2.2.3.2 信頼性	7
2.3 設計の基本思想と目的	8
2.4 システムの動作原理	9
2.4.1 紙幣識別に関する知識とその管理	9

2. 4. 2	紙幣識別用知識の選定	1 2
2. 4. 3	設計パラメータ候補の絞り込み	1 3
2. 4. 4	システムに対する設計者の介入	1 4
2. 5	システムの構成	1 6
2. 5. 1	データ管理マネージャ (DCM)	1 9
2. 5. 2	グラフィックスデータマネージャ (GRM)	2 0
2. 5. 3	知識ベース実行マネージャ (KBM)	2 2
2. 5. 4	メニューハンドラ (MH)	2 3
2. 5. 5	システム環境	2 5
2. 6	実験結果と考察	2 5
2. 6. 1	推論結果	2 5
2. 6. 2	評価指標による考察	2 6
2. 6. 3	特徴量抽出関数の分離能力による考察	2 7
2. 7	おわりに	2 8

第3章	FFTを前処理とするニューラルネットワークによる紙幣識別	3 0
3. 1	はじめに	3 0
3. 2	紙幣識別の概要と問題点	3 1
3. 3	ニューラルネットワークによる紙幣識別機構	3 3
3. 3. 1	時系列データの入力	3 5
3. 3. 2	フーリエ係数の入力	3 5
3. 4	紙幣識別実験	3 8
3. 4. 1	紙幣識別機データ	3 8
3. 4. 2	シミュレーション条件	3 8
3. 4. 3	収束状況の比較	4 1
3. 4. 4	鑑別率の比較	4 2
3. 5	信頼性評価	4 4
3. 5. 1	従来の評価規範の問題点	4 4
3. 5. 2	信頼性評価規範	4 5
3. 5. 3	信頼性の比較	4 6

3. 6 おわりに	4 8
第4章 ニューラルネットワークを用いた高速搬送紙幣の識別	5 0
4. 1 はじめに	5 0
4. 2 紙幣識別の概要と問題点	5 0
4. 3 ニューラルネットワークによる紙幣識別機構	5 3
4. 3. 1 時系列データの入力	5 3
4. 3. 2 フーリエ係数の入力	5 4
4. 4 紙幣識別実験	5 7
4. 4. 1 紙幣識別機データ	5 7
4. 4. 2 従来の紙幣識別手法	5 8
4. 4. 3 シミュレーション条件	5 9
4. 4. 4 鑑別率の比較	6 0
4. 5 信頼性の評価法	6 1
4. 5. 1 従来の評価規範の問題点	6 1

4. 5. 2 信頼性評価規範	6 2
4. 5. 3 信頼性の比較	6 3
4. 6 おわりに	6 6
第5章 ランダムマスクによるニューラルネットワークの規模 の縮小化と紙幣識別への応用	6 8
5. 1 はじめに	6 8
5. 2 ランダムマスクによる画像特徴量算出の原理	6 9
5. 2. 1 画像特徴量としての画素値の総和	6 9
5. 2. 2 提案手法の構成法と基本原理	7 1
5. 2. 3 提案手法のWindow的解釈	7 4
5. 3 アルファベットを用いた実験	7 6
5. 3. 1 提案手法によるマスク数の検討	7 7
5. 3. 2 提案手法によるマスク領域の検討	7 9
5. 3. 3 従来手法との比較	8 1
5. 4 紙幣データを用いた実験	8 2

5. 4. 1 提案手法による実験	8 2
5. 4. 2 従来手法との比較	8 4
5. 5 提案手法を用いた他の応用例	8 6
5. 6 おわりに	8 7
 第6章 ランダムマスク方式によるニューロ紙幣識別機の開発	 8 9
6. 1 はじめに	8 9
6. 2 ランダムマスク方式によるニューロ紙幣識別の原理	8 9
6. 3 実験システムの構築	9 1
6. 3. 1 システム構成の概要	9 1
6. 3. 2 ハードウェア構成	9 3
6. 3. 3 ソフトウェア構成	9 4
6. 4 紙幣データによる実験	9 6
6. 4. 1 学習法と識別データ	9 6
6. 4. 2 識別結果	9 7

6. 5 おわりに	9 8
-----------	-----

第7章 おわりに	9 9
----------	-----

参考文献	1 0 1
------	-------

関連発表論文	1 0 3
--------	-------

謝辞	1 0 4
----	-------

第 1 章 はじめに

貨幣は現代の高度情報化社会において経済価値の基本媒体である。その歴史は古く、紀元前から現在まで永々と人間社会に浸透している。貨幣の物理的容貌は石、金、銀、銅、紙等と現在までに種々変化してきている。しかしながら、その基本的機能である経済価値を代表するという点には変わりはない。

今日、情報技術の急速な発展と生活様式の多様化とあいまって、この貨幣識別の O A 化が急務とされている。本研究はこの貨幣識別をより精度良く、効率的に行うべく、貨幣識別への知的情報処理の応用に関する研究を行ったものである。一般に、紙幣識別機は市場ニーズとして、一秒間に 10 枚以上の紙幣を識別する能力、さらに、製品としてはハードウェアの低コスト化と装置のコンパクト性が要求されている。したがって、製品化においてはアルゴリズムそのものを演算量の少ない単純なものにすることが必要である。そのために画像処理あるいは多変量解析を用いたパターンマッチング処理を採用した紙幣識別機はほとんど製品化されていないのが現状である。一方、紙幣識別機開発の分野では以前から独自の識別式が考案され、この方式による製品化が行われてきた。この識別式は基本的に加算、減算、比較の各演算子を用いて紙幣の特徴を表現したものである。しかしながら、識別式を構成するパラメータは、設計者が金種の違い、データ収集時の紙幣の回転、位置ずれ、起伏によるデータ変動などを想定して決定している。このような方法ではパラメータの組合せ数が非常に多く、得られた組合せが最適であるか否かの保証はなされていない。したがって、設計目標に到達したか否かを大量の紙幣データを用いて実験的に検証し、多大な工数を要して識別機の開発を行っている。さらに、設計者のノウハウおよび経験である紙幣識別に関する知識は個々の単発的な処理手続きであり、パラメータ決定を行う際には一貫した処理フローを作成するのが困難である。本研究では、このような専門家の試行錯誤の作業分野に知的情報処理のアプローチとして、まず、エキスパートシステムを導入する。

第 2 章では紙幣識別の分離関数である識別式決定に対するエキスパートシステムの構築について述べる。エキスパートシステムを識別技術に導入することにより、従来技術と比較して開発期間および識別性能の点において大幅に向上が見られるこ

とを示す。しかしながら、ここでのエキスパートシステムの効果は、紙幣の分離関数である識別式決定においてのみ有効であり、紙幣識別における識別式の限界（市場における紙幣に対する汚れ、破れなどのノイズ、さらにはセンサ系に対する信号ノイズなどのロバスト性の問題）は未解決となっている。

一方、本研究では紙幣識別分野の知的情報処理の他のアプローチとしてニューラルネットワークの応用について考察する。第3章および4章では、このニューラルネットワークを応用した紙幣識別手法について考察する。ここでは、紙幣識別に適したニューラルネットワークの構成ならびに入力情報の選定法についてフーリエ変換などを利用して考察する。また、紙幣識別の分野で従来から問題となっている識別結果に対する信頼性に対して、新たに信頼性評価規範を導入し、識別性能について検討を加える。さらに、ニューラルネットワークを応用した紙幣識別手法が、識別性能と開発期間の点から、従来の分離関数方式やパターンマッチング方式と比較して非常に有効な手法であることを述べる。

しかしながら、これらの種々の検討結果を基に、ニューラルネットワークを実際の8ビットあるいは16ビットのCPUを有する識別機に移植する場合、ネットワークの規模の大きさが問題点として残されている。すなわち、ネットワークの規模は識別機へのニューラルネットワークの実装化の容易性以外に識別機のコンパクト性、処理速度、コストなどに大きく関係している。そこで、本研究では入力画像の一部を任意に被覆するランダムマスクを提案する。第5章では、このランダムマスクによるニューラルネットワークの規模の縮小化について述べる。ここでは、本提案手法により入力画像情報を容易に圧縮することが可能であることを示す。さらに、従来のニューラルネットワークを用いた手法と比較して、提案手法が識別性能の劣化を最小限にとどめ、大幅なネットワークの規模の縮小化を可能にしていることを定量的に示す。また、提案手法により特殊なデバイスを用いなくても実システムが容易に構築可能であることを既存の識別機とパーソナルコンピュータを用いて具体的に示す。第6章では、このランダムマスクによるニューロ紙幣識別機の開発について述べる。ここで開発する実験システムにより、日本、韓国、米国の複数国紙幣が混合した場合の紙幣識別が実現可能であることを述べる。

最後に、第7章では本研究のまとめと今後の展望について述べる。

第2章 紙幣識別の識別式決定に対する エキスパートシステム

2.1 はじめに

近年、エキスパートシステムの実システムへの応用に関して多数の報告がなされている^{1)~3)}。とくに、設計型エキスパートシステムの構築では対象によってルール、フレーム、意味ネットワーク、それらのハイブリッドなどにみられるように、対象システムの特徴を活用した知識表現と推論システムが必要である^{1)・4)}。本章では、紙幣識別への知的情報処理のアプローチとして紙幣識別用のエキスパートシステムを検討し、実際の紙幣識別問題へ応用することによりその有効性を検証する。

一般に、紙幣識別機において、その市場ニーズとしては一秒間に10枚以上の紙幣を識別する能力、さらに、製品としてはハードウェアの低コスト化と装置のコンパクト性が要求されている。このため製品化においてはアルゴリズムそのものを演算量の少ない単純なものにすることが必要である。このような理由で画像処理あるいは多変量解析を用いたパターンマッチング処理^{5)・6)}を採用した紙幣識別機はほとんど製品化されていなかった。それゆえ、紙幣識別機開発の分野では以前から独自の識別式が考案され、この方式による製品化が行われてきた。この識別式は基本的に加算、減算、比較の各演算子を用いて紙幣の特徴を表現したものである⁷⁾。しかしながら、識別式を構成するパラメータは、設計者により金種の違い、データ収集時の紙幣の回転、位置ずれ、起伏によるデータ変動を想定して決定されている。この方法ではパラメータの組合せ数が非常に多く、得られた組合せが最適であるか否かの保証はなされていない。したがって、設計目標に到達したか否かという指標に基づいてのみ開発を行っているのが現状である。さらに、設計者のノウハウおよび経験である紙幣識別に関する知識は個々の単発的な処理手続きであり、パラメータ決定を行う際には一貫した処理フローを作成することが困難である。ところで、エキスパートシステムは以下のような特徴を有しており、上述の困難な問題を残していた紙幣識別のための識別式のパラメータ決定作業を自動化する上で有効な手法と思われる。

- (1) 経験則を知識データとして表現し、管理できる^{1), 2)}。
- (2) 識別式のパラメータ決定の処理フローを推論過程で動的に決定できる^{1), 2)}。
- (3) 識別式のパラメータ決定に至る個々のデータの処理手続きをイベントという単位で取り扱うことができ、設計者とのマンマシンインターフェース（以後MMIと略記する）をこのイベントに連携させて動作させることができる³⁾。

本章では、紙幣識別に設計型エキスパートシステムを応用し、紙幣識別に用いる識別式群を相反する制約条件（目標）のもとで決定するルールベースのプロダクションシステムを構築する^{1), 2), 4)}。とくに、本システムの設計では設計者固有の知識（ノウハウ、経験）を整理・体系化し、従来設計者が手作業で行っていた識別式群決定作業を非線形最適化問題として定式化する。まず、従来の識別式決定法について述べ、その問題点を指摘する。つぎに、本章で提案するエキスパートシステムの基本設計思想と目的について述べる。さらに、識別用設計型エキスパートシステムの新しい構成を提案する。最後に、本システムを用いて決定した識別式群を従来の手法で決定した識別式群と比較検討し、ここで提案したシステムの有効性をシミュレーションにより定量的に検証する。

2. 2 従来の識別式決定手法

従来の設計者による紙幣識別のための識別式群を決定する作業は以下のようになっている⁷⁾。まず、紙幣を識別するためのポイント（識別点）群を各種センサの紙幣時系列データから抽出する。抽出された識別点群から特徴抽出関数を決定し、この関数により得られる紙幣代表値を用いて識別式を決定する。これらの識別式群を用いて紙幣識別が実行される。

Fig.2.1はセンサデータ波形、識別点、識別式の三者の関係を示しており、横軸は紙幣搬送方向、縦軸はセンサ値を示している。ここで、センサデータ波形とは、紙幣の特定部位をセンサで一定間隔にサンプルした時系列データのことである。また、Fig.2.1の識別点探索は、識別紙幣である目的モードと被識別紙幣である排除モードの識別点群（A, B）と特徴量抽出関数によるそれぞれの紙幣代表値（A値, B値）を表わしている。この場合、目的モードのセンサ値の平均値を用いるとA値-B値

として160が得られる。一方、排除モードからは同様にA値-B値として-50が得られる。したがって、しきい値を仮に100に設定すると、目的モードの紙幣と排除モードの紙幣が分離できる。なお、ハッチング部分は紙幣の搬送などによって生ずるセンサデータ波形のばらつきを表わしている。




Fig.2.1 Decision of discriminative function by use of sensing data.

2. 2. 1 特徴抽出関数

ここではまず、前述した紙幣代表値を得るための特徴抽出関数について述べる。特徴抽出関数は、以下の式(2.1)で与えられ、紙幣のセンシング時系列データの特徴である凸凹（山谷）パターンの内、分離能力に応じて抽出した識別点群より構成される関数である。これらの識別点群は識別紙幣と被識別紙幣の間で決定され、また、識別点の位置と数は識別紙幣と被識別紙幣との間で固有のものである。

$$f_i = f_i(a_{i1}, a_{i2}, \dots, a_{im}, b_{i1}, b_{i2}, \dots, b_{in})$$

$$a_{ij} \in A, b_{ik} \in B \quad (2.1)$$

$$i=1, 2, \dots, l, j=1, 2, \dots, m, k=1, 2, \dots, n$$

ここに, l : 特徴量抽出関数の個数, m, n : i に依存する識別点の個数, A ,

B : 識別点群, a_{ij}, b_{ik} : 識別点を示す.

以下では, この特徴抽出関数を用いた紙幣識別のための識別式について述べる.

2. 2. 2 識別式

識別式は, 以下の式(2.2)で与えられ, 特徴抽出関数にしきい値を付加した不等式である.

$$f_i = f_i(a_{i1}, a_{i2}, \dots, a_{im}, b_{i1}, b_{i2}, \dots, b_{in}) \geq \theta$$

$$a_{ij} \in A, b_{ik} \in B \quad (2.2)$$

$$i=1, 2, \dots, l, j=1, 2, \dots, m, k=1, 2, \dots, n$$

ここに, θ はしきい値を示し, それ以外の変数は式(2.1)と同じものを意味している. 紙幣の時系列データをこのような不等式で評価することにより, 識別紙幣と被識別紙幣を分離することができる.

なお, 式(2.2)の不等式は, 特徴抽出関数に従属するものであり, 識別紙幣と被識別紙幣との間で固有のものである.

2. 2. 3 識別式群決定の評価

識別式群の性能評価に対しては, 以下に定義する鑑別率と信頼性の二つの評価指標が従来から経験的に用いられている.

2. 2. 3. 1 鑑別率

これは, 目的紙幣的中率を示す指標であり, 次式で定義される⁸⁾.

$$E_1 = \frac{(\text{目的の金種として識別された枚数})}{(\text{全紙幣評価枚数})} \times 100 (\%) \quad (2.3)$$

2. 2. 3. 2 信頼性

これは, 目的外紙幣の排除率を示す指標で次式で定義される⁸⁾.

$$E_2 = \int_{-\infty}^{\theta} \frac{1}{(2\pi)^{1/2} \sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) dx \quad (2.4)$$

ここに, x : 排除紙幣の紙幣代表値, σ : 排除紙幣の紙幣代表値の標準偏差, μ : 排除紙幣の紙幣代表値の平均値, θ : 目的紙幣と排除紙幣の紙幣代表値間のしきい値を示す.

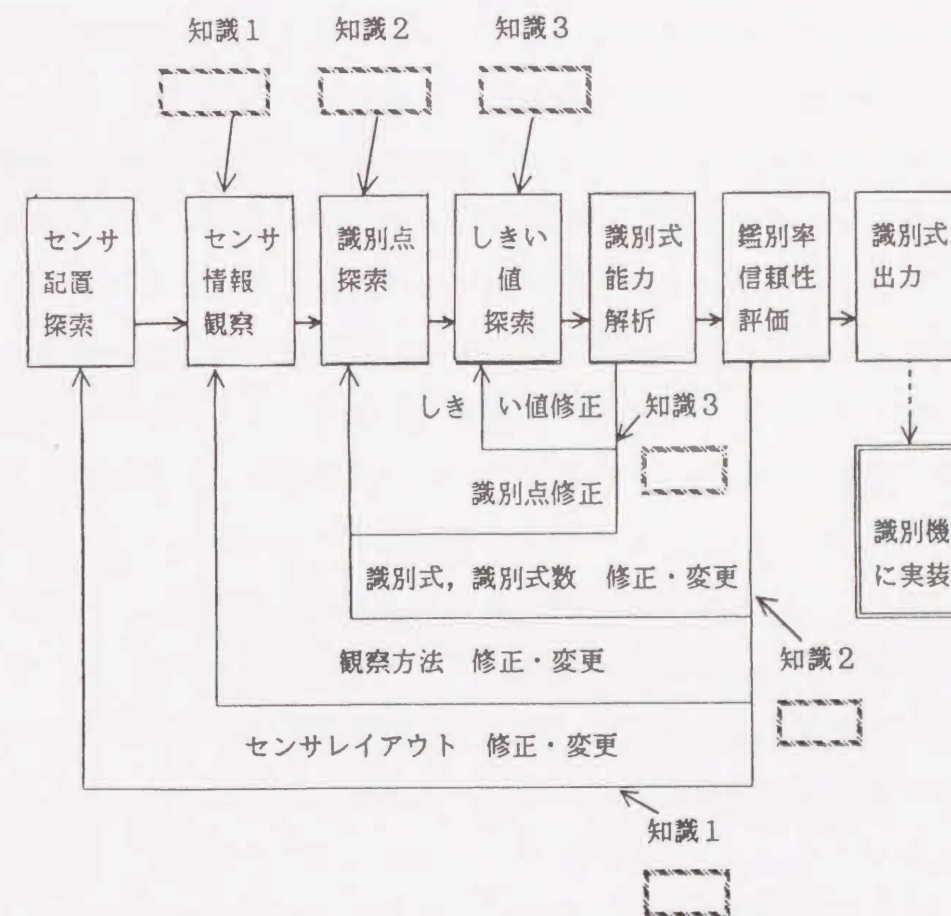


Fig. 2.2 Block diagram of decision procedure of discriminative functions.

従来の設計者による作業は, 識別紙幣と被識別紙幣間で分離するのに必要な識別式のパラメータ (a_{ij}, b_{ik}, θ_i) と識別式の個数 (l) を評価指標 (鑑別率 E_1 , 信

頼性 E_2) に応じて決定するものである。しかしながら、評価指標の値を用いていかに識別式のパラメータを調整するかは、設計者のノウハウと経験に依存しており、作業の体系化と標準化が困難であった。また、従来の識別式決定においては、数カ月に及ぶ作業工数を要していた。Fig. 2.2 に従来の設計者による識別式群決定作業のブロック図を示す。知識 1, 2, 3 は、それぞれ、センサ情報を観察するノウハウ、識別式のパラメータである識別点探索のノウハウ、しきい値と不等号探索のノウハウを示し、作業過程で設計者によって随意使用される。

2. 3 設計の基本思想と目的

従来、設計者が行っていた識別式群の決定作業においては、データの観察、識別点の抽出、しきい値の設定などが試行錯誤的に行われていた。また、識別式探索においては、設計者により決定された識別式を用いて紙幣データを評価した場合、識別式の評価指標（設計目標）である鑑別率と信頼性の値が得られる。そのためこれらの評価値に基づいて、さらに優れた識別式を得るための探索をいかに行うかは、個々の設計者が有するノウハウおよび経験に大きく依存している。

本章では、識別式決定において作業の標準化と短縮を図るため、設計者を代行あるいは支援する識別処理手続きに最も適した固有の設計型エキスパートシステムを構築することを目的としている。ここで提案するシステムの設計は、従来の設計者の手作業による作業フローを踏襲し、設計者の確認・介入を許容する協調推論システムとする。したがって、本システムでは、データ観察から識別式評価までをエキスパートシステムで構築する。とくに、処理過程における確認と介入において、以下の視点からシステムを構成する。

- (1) 識別式のパラメータ決定の必要情報の提示。
- (2) 最適パラメータ決定へのガイドラインの設定とその経緯の提示。
- (3) システムの可調整。

まず、従来のエキスパートシステム構築ツールを用いて、エキスパートシステムを構築する際の問題点をシステムへの知識移植を行う場合を例にとり以下に述べる。

一般に、プリミティブなエキスパートシステム構築ツールとしては LISP と PROLOG があり、また、これらの機能を高めたオブジェクト指向型の OPS 5 あ

るいは OPS 83 などが考えられる。これらの AI 言語でシステムを構築する場合、知識の詳細な記述が可能である。しかし、知識をそのシステムへ移植する場合、それぞれの言語のフォーマットで知識を記述しなければならない。したがって、エンドユーザである設計者はこれらの言語に十分精通することが要求される。一方、SUPER-BRAINS, ESHELL, EXCORE, ES-KERNEL などの汎用シェルでシステムを構築する場合、これらの汎用シェルは、知識表現法としてフレーム、ルール、意味ネットワーク、さらに一部には、ディシジョンテーブルを有している。これらの汎用シェルの知識表現法を用いた場合、そのインターフェースは、前述の AI 言語のフォーマットよりは設計者にとってシステムへの知識の移植の容易さの点で優れている。ところで、紙幣識別の知識表現法としてはルールが代表的なものとして考えられる。しかし、前述の汎用シェルはあくまで汎用性に比重をおいている。それゆえ、紙幣識別に固有の処理手続きをルールとして表現し、その知識をシステムに移植するには限界がある。また、汎用シェルは推論実行中における知識のデバッグにおいても十分な機能を有してはいない。そこで本章では、紙幣識別分野に限定し、AI 言語のような細かい知識表現と汎用シェルのようなシステムへの知識移植を容易にする MMI が充実したドメインシェルを構築する。

2. 4 システムの動作原理

2. 4. 1 紙幣識別に関する知識とその管理

本システムでは、式(2.2)で得られる識別式 $f_i = f_i(a_{i1}, a_{i2}, \dots, a_{im}, b_{i1}, b_{i2}, \dots, b_{in}) \geq \theta$ の a_{ij} , b_{ik} , θ_i , i , m , および n をシステムの設計パラメータとしている。ただし、システム管理者が識別式の関数形 f をシステムに与えるように設計されている。本章で適用する識別式の関数形は、従来の手作業による手法と同じ関数形 f_i を採用し、 a_{ij} の総和から b_{ik} の総和を差し引くものとする。したがって、式(2.2)から実際の識別式は以下ようになる。

$$\sum_{j=1}^m a_{ij} - \sum_{k=1}^n b_{ik} \geq \theta_i \quad (2.5)$$

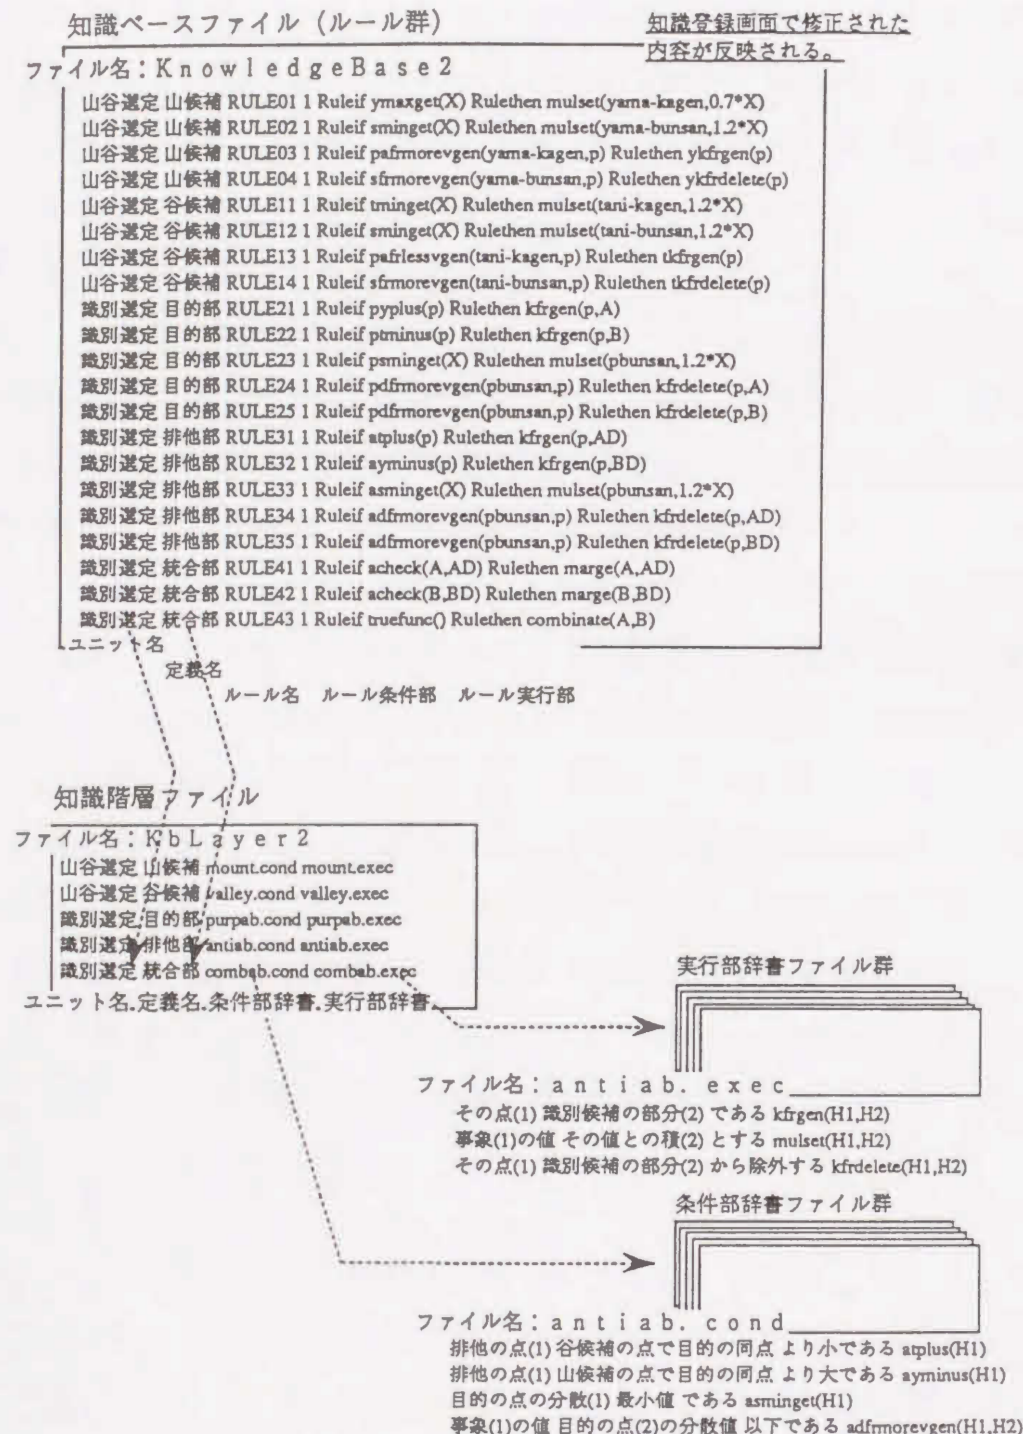


Fig.2.3 Relation of knowledge management files.

提案するシステムは、上述の識別式のパラメータを探索するための種々の知識を必要としている。すなわち、一つは紙幣時系列データの形状的特徴である山部（凸部）と谷部（凹部）を選定する山谷選定知識である。他の一つはこれらの山部または谷部が識別点に成り得るか否かを判定し、種々の識別点の組合せを決定する識別選定知識である。山谷選定知識は山候補選定知識と谷候補選定知識より成る。また、識別選定知識は目的とする紙幣側から識別点を選定する目的部選定知識と排除される紙幣側から識別点を選定する排他部選定知識より成る。それぞれの知識は、ルールとして表現され、そのルールは一つ以上の条件部と一つの実行部で構成される。さらに、知識はシステムによって知識ベースファイルと知識階層ファイルおよび辞書ファイルの3つのファイルによって管理される。知識ベースファイルでは、知識がルールとして記述され、そのフォーマットは（ユニット名／定義名／ルール名／ルール条件部／ルール実行部）となっている。ただし、ルールの条件部および実行部のどちらも文書ではなく、システムが直接操作できる関数名であり、設計者はこの部分を意識する必要はない。

また、知識階層ファイルでは知識をユニット名／定義名／条件部辞書名／実行部辞書名の構造によりディレクトリ構造として管理している。辞書ファイルにはルールの条件部と実行部の命題文書とこれに対応する関数名が記述されている。設計者は知識編集メニューによりルールの命題文書を編集する。システム側では命題に対応する関数が連動し、ルールを文書レベルで編集することができる。以上の具体例をFig.2.3に示す。図中の矢印が各知識管理ファイルの関係を示している。知識編集の場合、設計者はこれらのファイルを直接操作するのではなく、知識編集メニューでマウスとキーボードから間接的に各ファイルの内容を更新する。Fig.2.4はこれを具体的に示したものであり、知識階層に表示されたルール（図中の右上側）を指定した場合の条件部と実行部を表示している（図中の左下側）。たとえば、Rule1の条件部の命題を指定した場合、その命題が主語／目的語／述語に分解され、それに対応した関数名も表示される（図中の右下側）。この図の右下側の命題編集メニューにおいて矢印をマウスで指示することにより、辞書に登録された単語が規定された組合せにより表示される。意図する命題が決定されれば、設計者は条件部あるいは実行部にこの命題を組み込み、日本語文章レベルで容易に知識を編集することが可能となる。また、新たな単語を必要とする場合は、システム管理者が辞書を

含めた知識管理ファイルにその単語と組合せ情報およびデータ処理関数を登録する。




Fig. 2.4 Window for editing knowledge.

2. 4. 2 紙幣識別用知識の選定

本システムではシステムの推論効率を高めるために、識別式のパラメータ探索処理に関する知識作成においては、その知識がどのような分類に属する知識であるかについて可能な限り考慮しなければならない。つまり、前述したようにパラメータ探索処理の経験とノウハウを表わす知識は *if-then* 形式の文書（ルール）として作成することができる。作成された知識を既存の知識群のどの分類に挿入ある

いは追加するかに関しては、メタ知識のような上位の知識を用いしないで、設計者が直接決定する構造となっている。もちろん、分類内においては、処理のシーケンスはシステムにより動的に決定されるため、設計者は知識の発火シーケンスを考慮する必要はない。また、推論状態表示メニューにより推論実行中に知識全体がディレクトリ構造で表示され、さらに、動的にルールの発火が表示される。この機能により新しい知識の分類に関する挿入あるいは追加位置の良否が判定でき、そのときのデータ処理状態もウインドウにより確認することができる。したがって、設計者はこれらのシステムの知識獲得に関するデバッグ機能を使用することによって、知識の選定と推論の効率化を行うことが可能となっている。

2. 4. 3 設計パラメータ候補の絞り込み

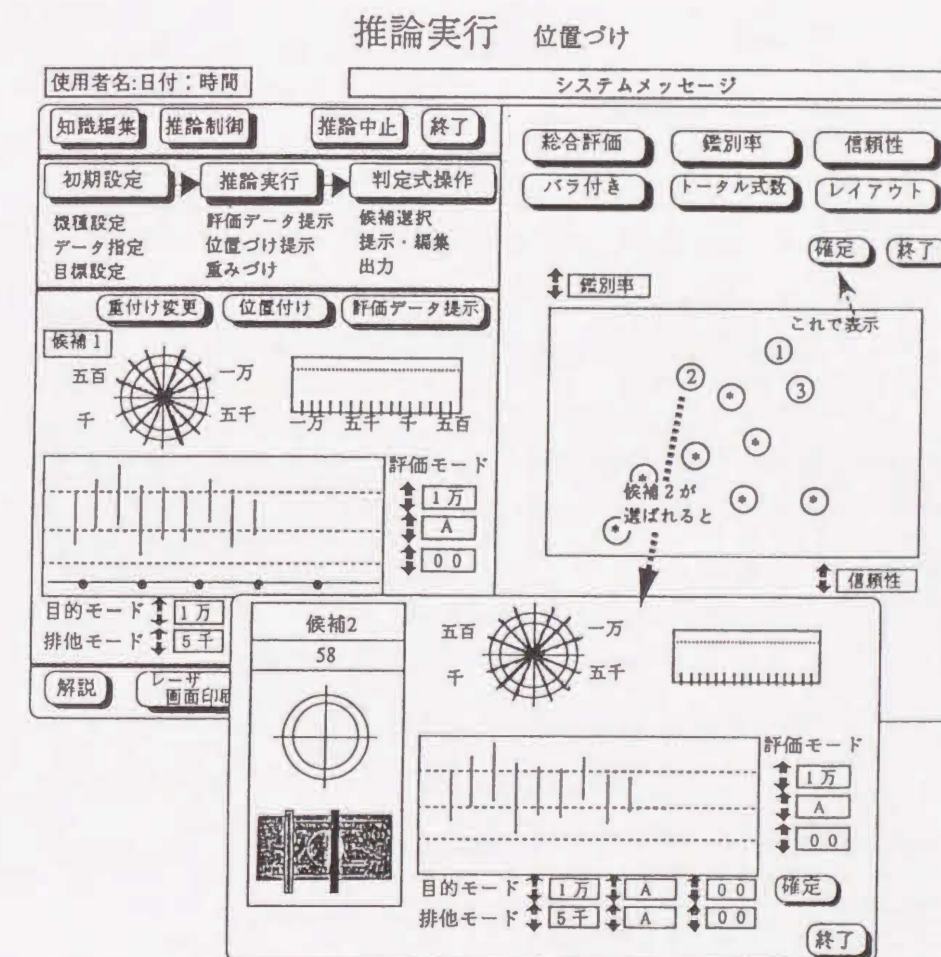


Fig. 2.5 Window for selecting parameter candidates.

本システムは識別式のパラメータ群の候補を設計目標である鑑別率と信頼性への達成率に従い上位から順序付けを行う。ただし、目標への達成率は（個々の目標に対する識別式の実績）／（目標値）×100で算出している。さらに、この目標への達成率に重み付けを行い、鑑別率優先あるいは信頼性優先の順序付けにより、候補の絞り込みを行うことが可能となっている。システムはこれらの順序付けられた候補を管理し、設計者の意図により特定の目標間で位置付けを行い、設計者の確認を得て、一組の識別式群を出力する。以上の関係をFig. 2.5に示す。この図は複数の候補を鑑別率と信頼性で位置付けし、候補2の識別性能を確認している状況を示している。ただし、ここで図中の目的モードおよび排除モードはそれぞれ識別紙幣と被識別紙幣を示している。また、評価モードはシステムで評価される紙幣データの種類を意味している。

2. 4. 4 システムに対する設計者の介入




Fig. 2.6 Window for changing qualified points.

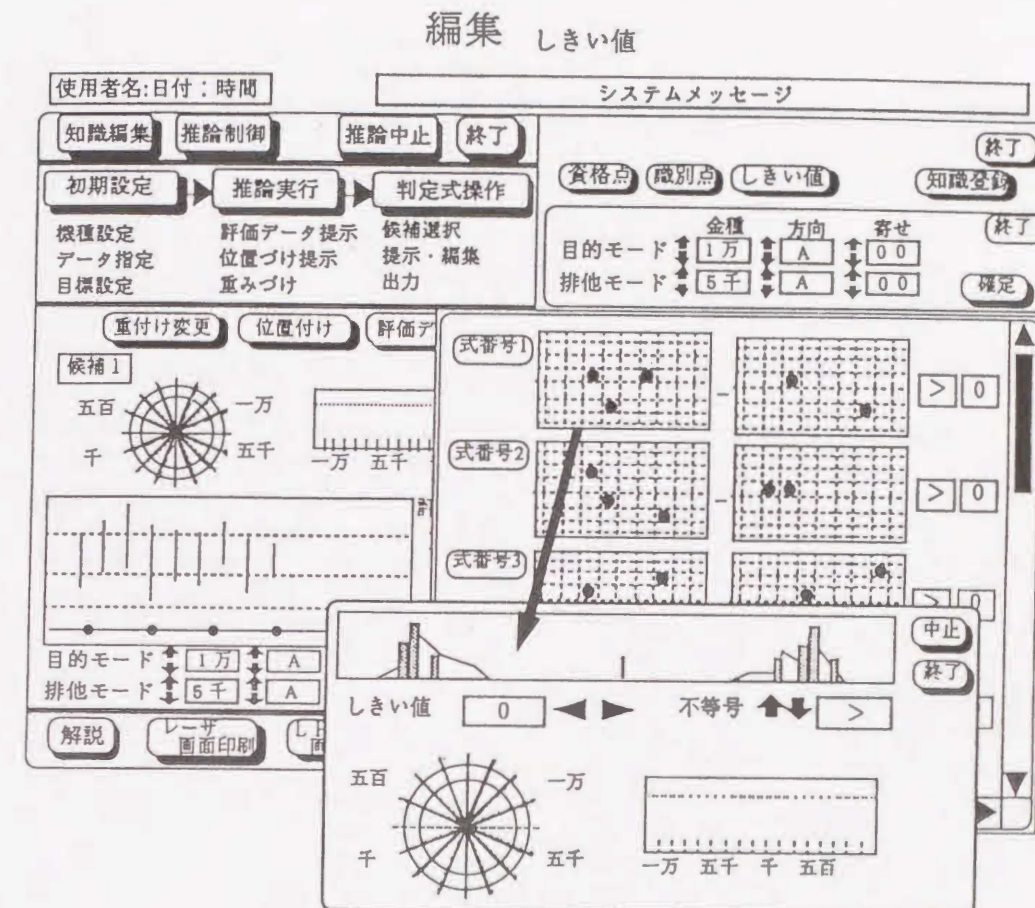


Fig. 2.7 Window for changing threshold values.

設計者が介入する場面は二つあり、一つは推論実行中の動的場面であり、一つは推論終了後の静的場面である。動的場面では、ルールの各命題に対応した関数を用いて処理されたデータの処理結果が表示され、システムは必要に応じて設計者の確認を待つ。また、推論実行中に複数の候補から決定される識別式の性能が目標に達しない場合、システムは識別式の候補のパラメータ変更を設計者に求める。とくに、これらの候補のパラメータの変更においてシステムは、専用のウィンドウにより紙幣時系列データや中間情報をグラフと数値で表示する。設計者はマウスとキーボードから容易にパラメータ変更を行うことができ、また、即時に変更結果を確認することができる。これらの設計者の変更データに基づいてシステムは推論を継続する。Fig. 2.6は前述の動的場面においてシステムが選定した谷部（図中の方形部分）

を第1センサから得られる時系列データに対して表示している。設計者は、谷部として適当でないと判断すればマウスで直接谷部の位置を変更することができる。ただし、図中で指定モードとは表示された時系列データの種類（金種、搬送方向など）を表わしている。

また、静的場面では、設計者は推論終了後に複数の識別式候補を直接指定し、その識別能力を確認することができる。動的場面と同様に指定した識別式のパラメータを直接変更し、即時に変更後の識別式の能力を確認することができる。Fig.2.7は決定された識別式のしきい値を目的モードである1万円のデータと排除モードである5千円のデータを用いて調整する状況を示している。図の左側のヒストグラムが5千円を示し、右側のものが1万円を示す。さらに、中央の実線がしきい値を示している。ただし、ここで式番号とは識別式の番号を示している。また、図中のメッシュは紙幣を示し、左側のメッシュは前述の式(2.5)の識別点 a_{ij} を右側のメッシュは b_{ik} を、それぞれ、示している。以上の工夫点をシステムで実現するための各基本モジュールの機能の概要を以下で述べる。

2.5 システムの構成

提案するシステムは、通常のエキスパートシステムと同様な基本構成から成っている^{3), 4)}。その主な構成要素は、データ管理マネージャ (DCM)、グラフィックスデータマネージャ (GRM)、知識ベース実行マネージャ (KBM) という3つの基本モジュールとそれらのMMIのエントリ部となるメニューハンドラ (MH) である。Fig.2.8に全体的なシステム構成を示し、各基本モジュールとMHの関係を示す。また、Fig.2.9にシステムの実行手順と画面構成を示す。さらに、画面の具体例として本システムの”初期設定”画面をFig.2.10に示す。ここで設計者は、推論や知識の編集の対象となる紙幣識別機の機種とセンサ配置を設定する。目的とするエキスパートシステムにおいては、紙幣識別に関して特有な知識表現ならびにシステムへの知識移植法、さらに、設計者とのMMIの設計法などの種々の工夫を必要とする。以下では、紙幣識別を意識したドメインシェルを構築するための個々のモジュールについて述べる。

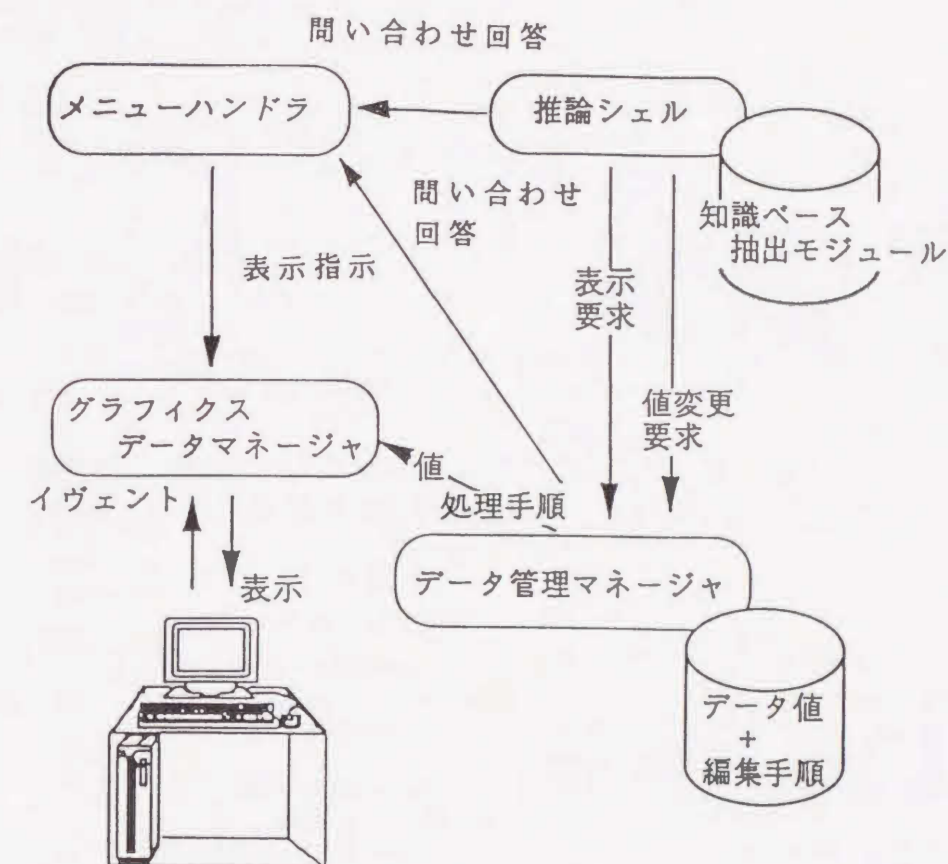


Fig.2.8 Total system construction.

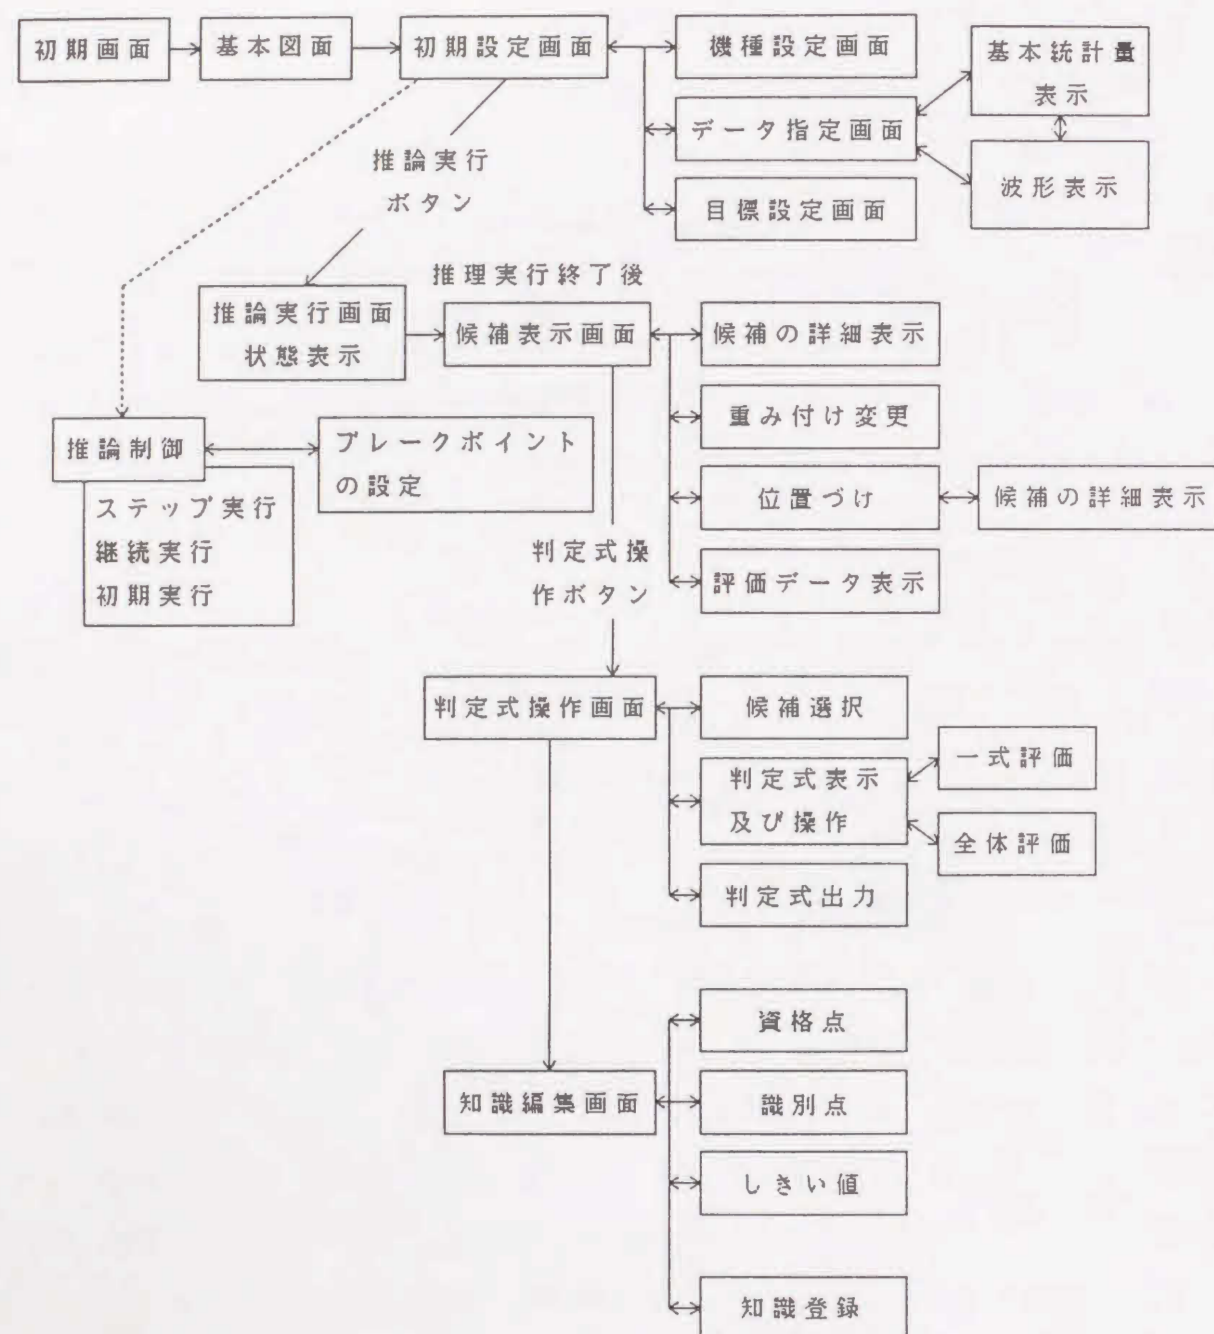


Fig. 2.9 System execution procedure and window construction.

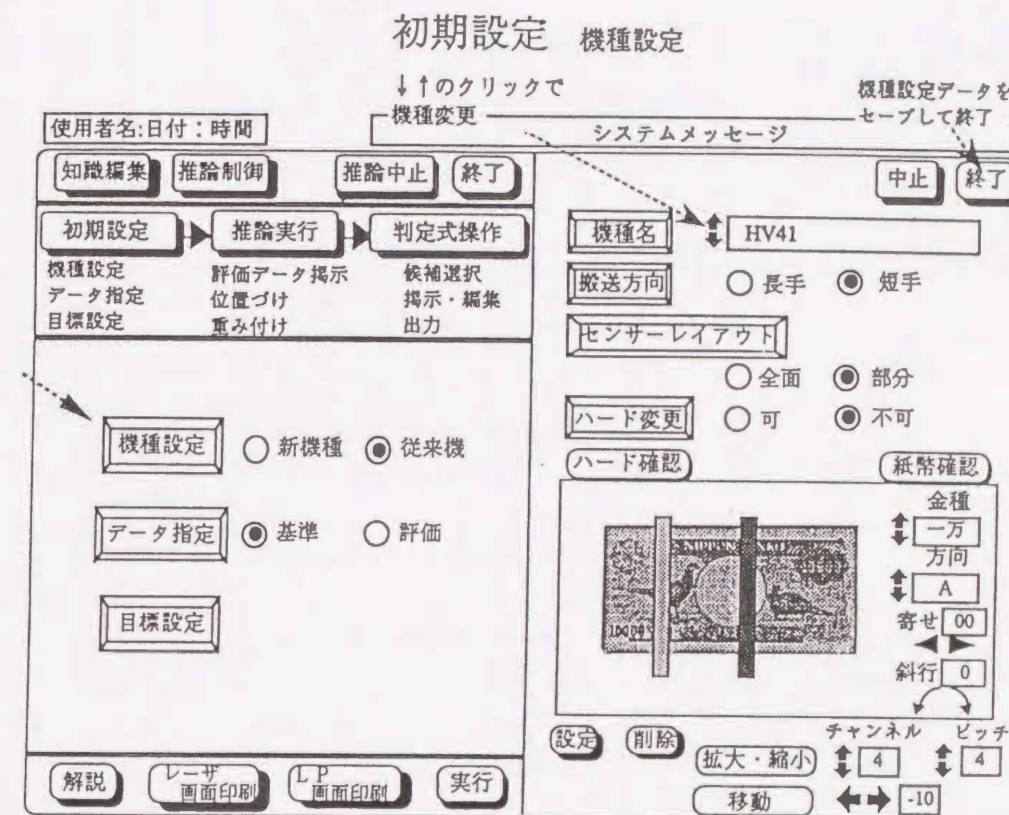


Fig. 2.10 Window for setting initial values.

2. 5. 1 データ管理マネージャ (DCM)

紙幣データは、紙幣一枚につき数キロバイトから数十キロバイトの容量を有している。したがって、大量の紙幣データを扱う場合、システムのアクセスを迅速かつ容易にする必要がある。そこで、紙幣データをその実情報とそれを管理する管理情報とに分け、リレーショナルデータベースを導入し、紙幣のデータ構造を階層構造とする。また、システムは目的モード、排除モード、サンプル、レイアウトごとに識別点を保有する必要がある。本システムではこれらのプロセス情報のデータ構造も階層構造としている。また、Fig. 2.11にDCMのシステム構成と他モジュールとのシグナルフローを示す。

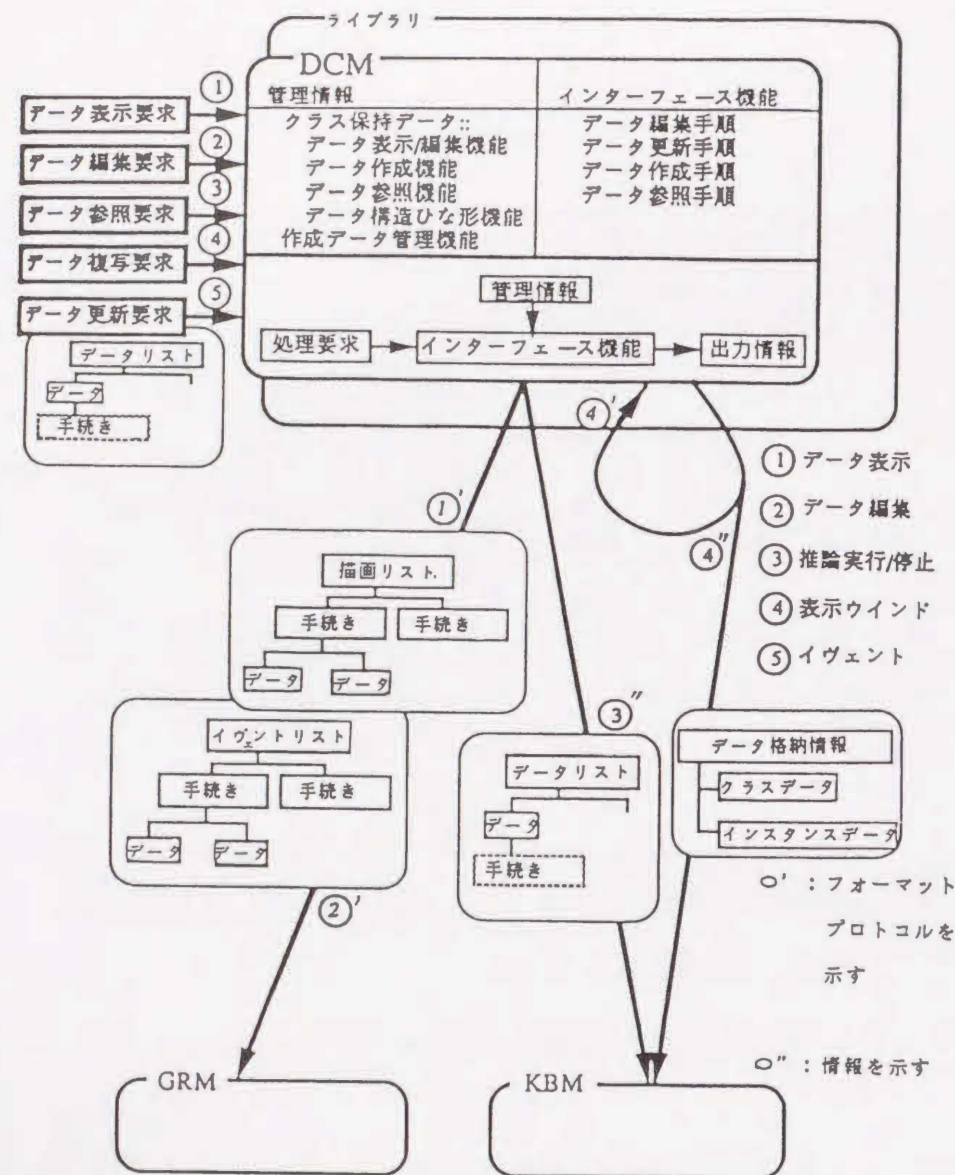


Fig. 2.11 Construction of DCM and its signal flow.

2. 5. 2 グラフィックスデータマネージャ (GRM)

本システムはブラックボックスとして扱われるのではなく、あくまで設計者の介入および確認を許容し、最終判定を設計者にゆだねるシステムとして構築されている。したがって、識別式群決定プロセスでは設計者との対話を重視した強力なMMIが与えられている。とくに、MMIは処理フロー情報を絶えず設計者に与える静

動的メニュー画面と設計者の意図に随時呼応して発生・動作する動的メニュー画面から構成されている。前者はタイリングメニューで、後者はポップアップメニューで実現されている。これらのメニュー画面は、識別式群決定のノウハウの一部つまり決定処理シーケンスそのものを具体化したものである。ただし、データ処理の手続き自体は関数処理であるが、メニュー画面の生成・消滅は処理結果と設計者の意図に依存させて柔軟性を持たせてある。また、Fig. 2.12にGRMのシステム構成と他モジュールとのシグナルフローを示す。

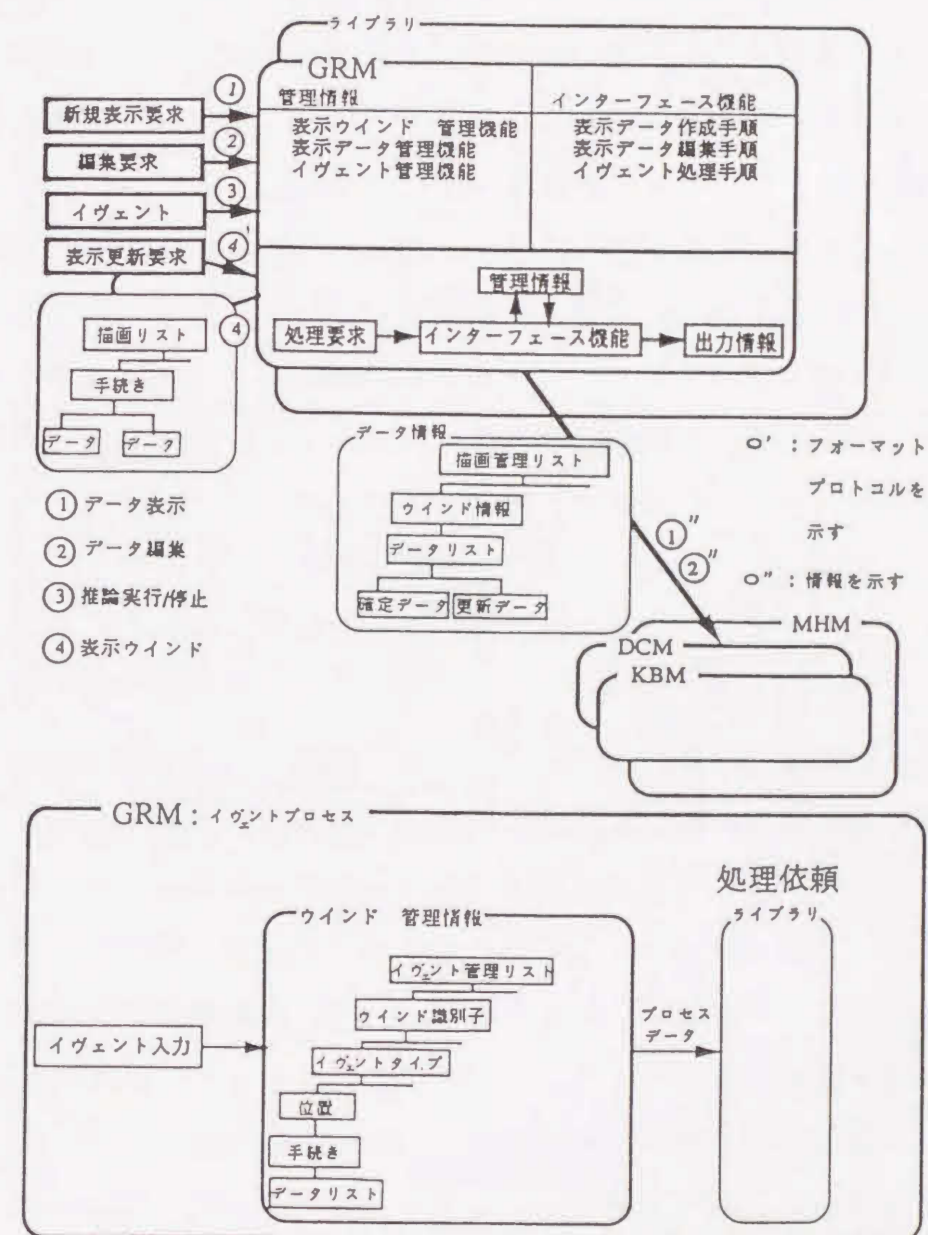


Fig. 2.12 Construction of GRM and its signal flow.

2. 5. 3 知識ベース実行マネージャ (K B M)

識別式群決定に至る推論のフローを識別用知識で詳細に制御するために、識別式群決定の知識をルールとして表現する。設計型エキスパートシステムとして候補となる推論方式には、前向き推論および前向き・後ろ向きのハイブリッド推論方式がある²⁾。ハイブリッド推論方式を採用した場合、知識の前後関係をあまり把握せず、単発的なデータ処理手続きのみを意識して作成した知識でもシステムの解を得ることが可能である。しかしながら、その解は目標に到達できない識別式のパラメータ候補ばかりとなる可能性がある。これを避けるためにここでは単純な前向き推論を採用する。それゆえ、ルール作成において、知識は処理結果に対し必要かつ十分なものでなければならない。そこで、本章では、日本語文章による知識獲得を可能とするために識別用のテンプレート機能を有する知識エディタの開発を行う。つまり、前述したように紙幣識別に関する知識はルールとして表現されるが、このルールは条件部と実行部より構成されている。条件部は一つ以上の条件命題より成り、実行部は一つの実行命題より成っている。それぞれの命題は、日本語文章で表現され、そのフォーマットは主語／目的語／述語となっている。システムは知識としてこの文書を取り込むのではなく、命題文章に1対1に対応しているデータ処理関数を取り込んでいる。それゆえ、命題文章は、関数のラベルとして活用される。したがって、設計者は知識をシステムに移植する際、上述の関数を直接扱うのではなく、それに付随する命題文章を扱うことになる。このように、本システムでは命題単位の編集が関数単位の編集になり、これにより知識の編集を行うことができる。とくに、この命題文章の主語／目的語／述語は辞書ファイルに登録され、これらの単語の組合せも知識ベースファイルに登録されている。設計者は知識編集メニューにおいて、マウスとキーボードから辞書ファイルに存在する許容可能な組合せの単語により、命題文書を編集することが可能となる。つぎに、ルールの発火プロセスは、以下に示す条件部処理と実行部処理から成っている。

(1) 条件部処理: 本処理は, 条件部に含まれる複数条件を全てマッチングさせた結果と各条件間の複合命題演算子をテンポラリデータとして残す. この処理は, 条件部に含まれるすべての条件を探索するまで継続される. 処理内容は, 条件部に付加された関数と引き数リストから決定される.

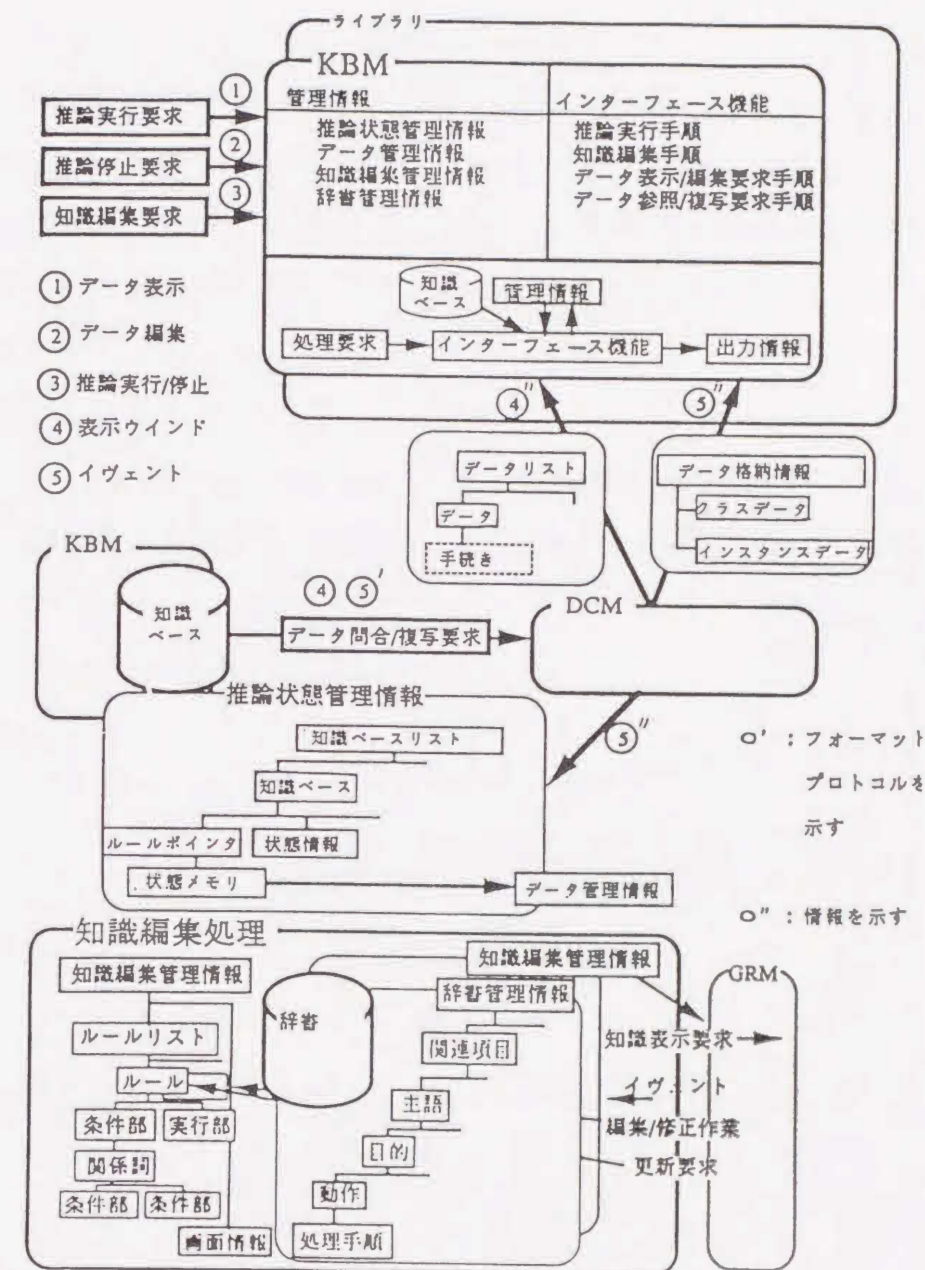


Fig. 2.13 Construction of KBM and its signal flow.

(2) 実行部処理: 本処理は, テンポラリデータを調査し, 条件部がすべて成立すれば実行部を実行する. 処理内容は, 実行部に付加された関数と引き数リストから決定される. また, Fig. 2.13にK B Mのシステム構成と他モジュールとのシグナルフローを示す.

2. 5. 4 メニューハンドラ (MH)

本モジュールは、設計者とシステムのMMIを実現し、同時にシステムの状態監視を行っている。また、このモジュールは、基本操作時（システムの起動、推論の中断、ルールの編集、推論終了など）におけるコマンド操作をプルダウンメニュー⁴⁾により提供し、GRMを起動する。本モジュールによるコマンド要求は、状態に応じてそれに対応する実行モジュールに引き継がれる。また、Fig.2.14にMHのシステム構成と他モジュールとの情報流れを示す。

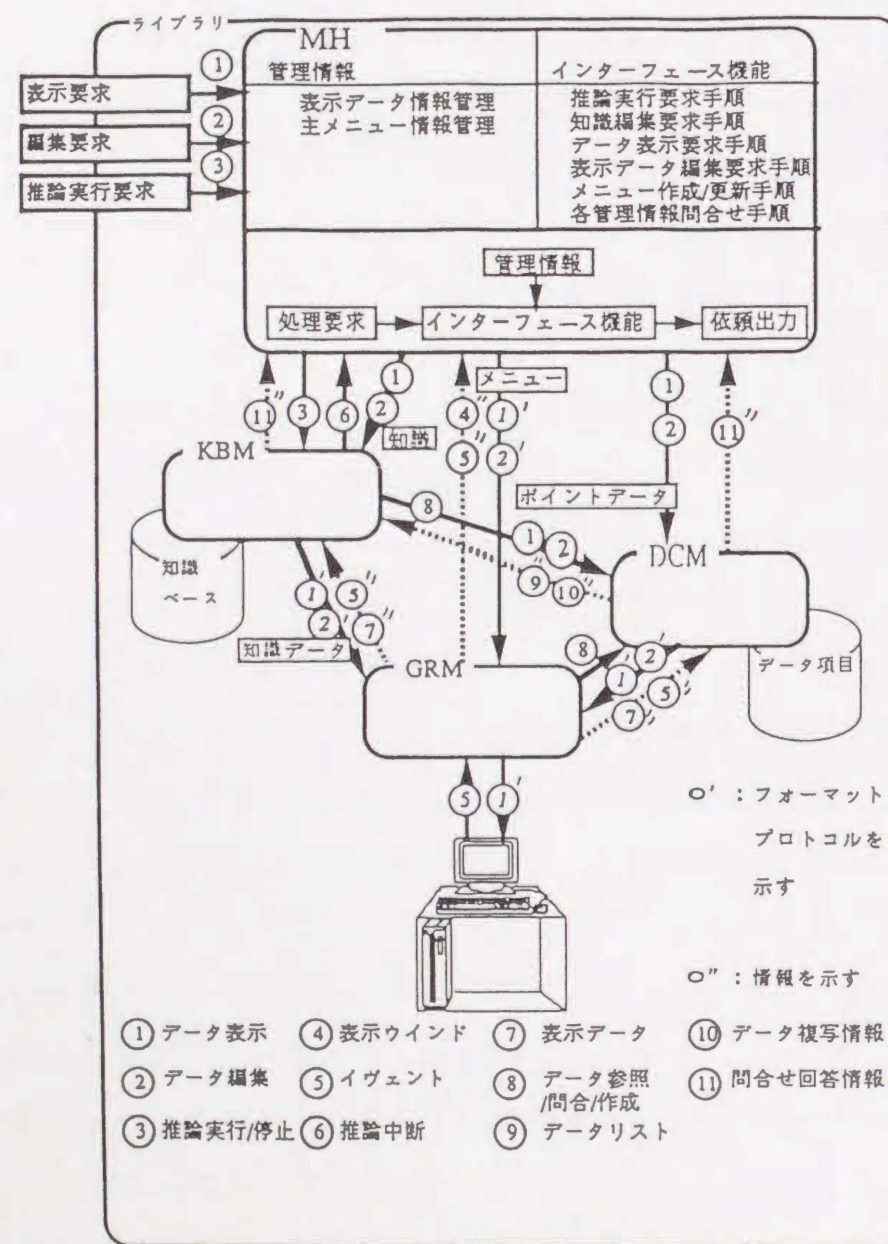


Fig.2.14 Construction of MH and its signal flow.

2. 5. 5 システム環境

本システムでは、カーネル部であるKBMはCOMMON-LISP言語で記述され、他の実行処理モジュールはC言語で記述されている。また、MMIは、Xウィンドウシステムを用いて構築されている。本章で構成したシステム規模は、ルール数30、プログラムサイズは約2万ステップである。システム本体は、UNIXワークステーション上で動作し、紙幣データはUNIXミニコンピュータにて管理されている。本システムは、ETHERNETを介してミニコンピュータの紙幣データをアクセス可能である。

2. 6 実験結果と考察

2. 6. 1 推論結果

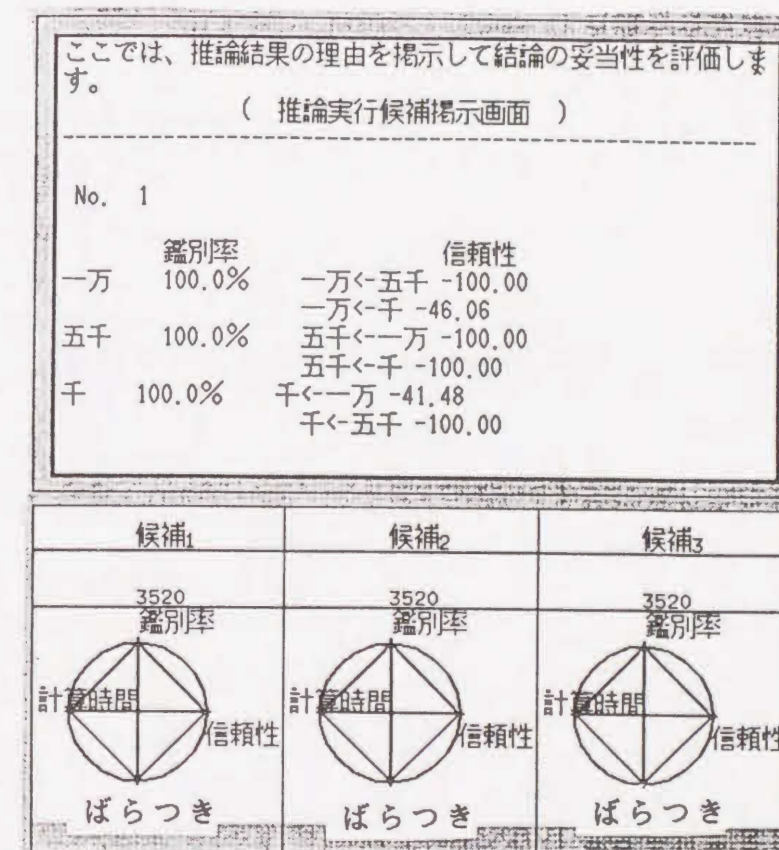


Fig. 2.15 Inference result.

Fig. 2.15は本システムの推論結果の画面を示している。本システムは決定された識別式群の上位3候補の目標（鑑別率，信頼性）達成率をレーダーチャートによって表示する。レーダーチャートは中心から半径方向に外に向かうほど達成率が良いことを示している。ここでは二次目標である許容できるデータのばらつきと計算時間を考慮して達成率を表示している。また，達成率の最も良い候補1の鑑別率，信頼性の数値を図中の上側に同時に表示する。実験では，上位3候補とも同じとなり，目標に到達していることが観察される。

2. 6. 2 評価指標による考察

本システムを用いて入力紙幣を3金種（1万円，5千円，千円）とし，それぞれ400枚を与え，識別式群を出力させた。出力した識別式群と従来の手作業で決定した識別式群とを別の紙幣3金種（1万円，5千円，千円）各800枚で評価した。




Fig. 2.16 Comparison of reliability.

評価指標は，鑑別率 E_1 ，信頼性 E_2 を用いた。この評価結果により，手作業で決定した識別式群の鑑別率は1万円，5千円，千円に対し，それぞれ，100%，100%，99.9%であった。一方，本システムで決定した識別式群の鑑別率は1万円，5千円，千円に対し，それぞれ，99.6%，100%，99.9%でほとんど同等であった。

また，Fig. 2.16に信頼性の比較を示す。図の横軸の誤鑑パターンとは，誤識別されるパターンを示している。たとえば（万→五千）は1万円を五千円に誤識別することを意味している。実験より，（万→五千），（5千→万），（千→万），（千→5千）に誤識別する場合の信頼性は手作業で決定した識別式群とシステムとでは，ほぼ同等であった。しかしながら，（万→千）に誤識別する場合の信頼性は，手作業で決定した識別式群の方がシステムで決定した識別式群より優れていた。また，これとは逆に（5千→千）に誤識別する場合の信頼性は，システムで決定した識別式群の方が優れていた。このことは手作業で決定した識別式群において，千円に関する固有のノウハウが含まれていることに起因している。したがって，本章で提案したシステムの知識データにこれらのノウハウを追加することによって，識別能力をさらに向上させることができると予想される。なお，本システムを用いて識別式群を出力するのに設計者が介入しないで動作した場合，4.5時間を要した。設計者による従来の手作業では，6月から7月を要していることを考慮すると本システムの有効性が検証された。

2. 6. 3 特徴量抽出関数の分離能力による考察

特徴量抽出関数を用いた目的モードと排除モードの実験による紙幣のヒストグラムの例（1万円と5千円の分離）をFig. 2.17に示す。紙幣一枚分のデータが特徴量抽出関数により，ヒストグラムの度数1になる。上記の場合と同様に，他のいずれのモードにおいてもデータ分布はあまり交差しておらず，システムによって選定された識別点群のしきい値は，すべて標準偏差の6倍以上に設定可能であった。設計者が設定した従来のしきい値は，標準偏差の3倍から8倍と偏った識別式となっていた。したがって，本システムで開発した識別式群は，従来手法で開発した識別式群よりもしきい値のばらつきが小さく，優れた識別点を得られていることがわかる。

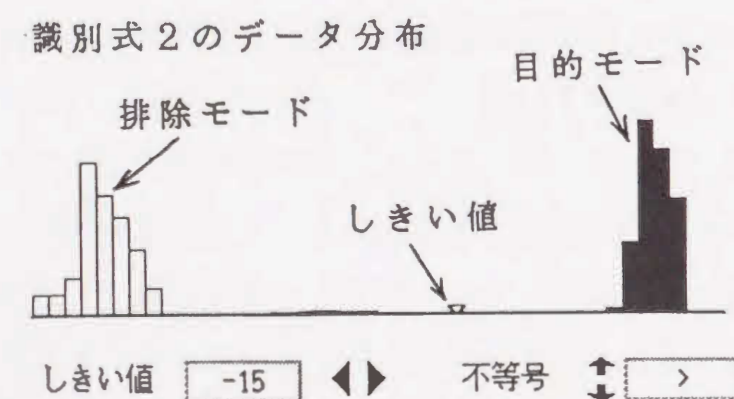
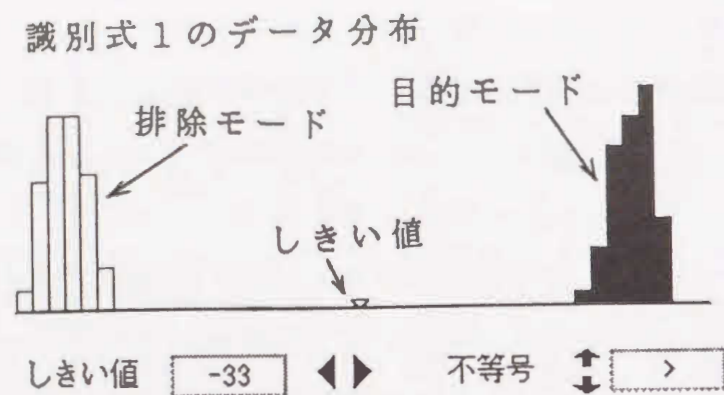


Fig. 2.17 Histogram between purposive mode and rejected mode.

2. 7 おわりに

本章では、設計者のノウハウと経験に基づいた識別式群を作成するために識別用設計型エキスパートシステムを構築した。このシステムを用いることにより、設計者がルーチンワークを経て作成したこれまでの識別式群と同等の性能を有する識別式群を自動的に得ることが可能となった。また、作成時間においては、従来月単位であったものを時間単位に短縮することができた。さらに、識別式自体は従来の手法で開発したものよりもしきい値のばらつきが小さく、優れた識別点を得られた。現在、ルールは30個であり、一連の推論プロセスにおいてすべて発火している。

ここで使用したルールは、知識獲得段階で識別式作成に至るまでのデータの観察方法、データのばらつきなどを考慮したものであった。さらに、本ルール以外にも局所的な最適ルールが存在することも実験において判明した。また、本システムは識別機の各種センサレイアウト（全面スキャン、部分スキャン、紙幣長手搬送、紙幣短手搬送）に即時に対応することを可能としている。

最後に、本章では紙幣識別のための識別式のパラメータ決定をエキスパートシステムで行ったわけであるが、次章からは紙幣識別への知的情報処理の他のアプローチとして紙幣識別そのものをニューラルネットワークで実現することを検討する。

第3章 F F T を前処理とする ニューラルネットワークによる紙幣識別

3.1 はじめに

本章からは紙幣識別への知的情報処理の他のアプローチとしてニューラルネットワーク（以後 NN と略記する）をその実現性と性能および開発期間などの点から検討する。

一般に、従来の紙幣識別機は、その市場における用途に応じて 10 枚/秒の処理能力を有する高速処理機から、1 枚/秒の通常処理機に至るまでの機種が製品化されている。しかしながら、その識別アルゴリズムは、搬送速度と演算量を考慮して、適材適所のものが採用されている。そのため、識別アルゴリズムは、識別機の仕様に応じて随時開発されている。つまり、設計者が搬送における紙幣の特徴パラメータを抽出し、このパラメータを用いて紙幣分離が可能か否かを大量の紙幣を用いて実験的に考察している。このような大量の紙幣の取扱い、紙幣の特徴パラメータの探索、採用する特徴パラメータによる紙幣分離可能性の検討などの業務においては、試行錯誤の域を脱却できず多大な工数を要しているのが現状である。

しかるに、生物の神経回路網の情報伝達をモデル化した NN は、情報の内挿、学習によるアルゴリズムの自己組織化、および並列処理などの優れた特徴を有し、種々のパターン認識に適している^{9), 10)}。とくに、学習によるアルゴリズムの自己組織化は、従来の経験による紙幣の特徴パラメータ探索業務を、軽減することが可能であると思われる。また、NN による情報の内挿能力は、搬送紙幣のデータ欠損やセンシングノイズに対して、ロバストな効果を有している。さらに、並列処理においては、識別処理のマルチタスク、およびマルチ CPU 化を可能としている。

本章では、NN を用いた紙幣識別手法を提案し、1 枚/秒の通常処理機の一部で使用されているパターンマッチングによる紙幣識別手法と比較することにより、提案手法の有効性を検証する。さらに、事前に判明する物理事象である、搬送むらによるノイズの影響を軽減するため、前処理として、紙幣の時系列データのフーリエ変換を行う。そこで得られるフーリエ係数は、紙幣の信号成分とノイズ成分とから

なるが、それらは周波数領域で、ある程度分離されて表現される。この入力情報の表現は NN にとって紙幣を分離する上で都合が良く、識別性能がさらに向上する。ここでは、このことを紙幣データを用いたシミュレーション実験により定量的に示す。

また、NN を用いた従来のパターン認識では、出力ユニットの最大値だけで性能評価が行われている。つまり、NN の出力ユニットの、最大出力値に主として注意が払われ、出力値の分布に関しては、あまり考察されていない^{8), 11) - 14)}。そこで、本章では、この出力ユニットの出力値の分布に着目し、他のパターンとして、誤認識される危険性を示す指標である信頼性評価規範¹²⁾を新たに導入する。たとえば、10 個の出力ユニットにおける出力値が (100, 98, 1, 1, 1, 1, 1, 1, 1, 1) と (100, 5, 1, 1, 1, 1, 1, 1, 1, 1) の場合では、出力の最大値を用いる限り、これらの認識結果はいずれも同じである。しかし、信頼性の点では、後者の場合の方がより優れていることは自明であり、この差異を明確にするためには、識別性能をより詳細に評価することが必要である。本章では、識別手法の性能評価指標として、従来の統計的確率とこの信頼性評価規範を用い、パターン認識性能をより詳細に検討する。

3.2 紙幣識別の概要と問題点

製品化されている紙幣識別機において、そのセンサは、Fig. 3.1 に示すように、専門家による種々の経験から、紙幣の特徴を最も代表する部分として、サンプルできるレイアウトがなされている。Fig. 3.1 内の点線の矩形は、個々のセンサが紙幣の搬送によりサンプルする領域を示している。識別機は、このように採取されたデータに基づいて、紙幣の識別を行っている。識別機能で見ると、上位機種は金種と搬送方向、それに紙幣の汚れ、穴あき、破れなどの判定から、下位機種は金種のみ判定に至る広範囲にわたっている。また、識別機への紙幣の挿入方法により、紙幣長手搬送と紙幣短手搬送の二種類に分類される。さらに、紙幣搬送速度の点では、10 枚/秒の高速処理から、1 枚/秒の通常処理に至る機能を有する識別機が製品化されている。とくに、高速処理に属するのは、ほとんどが、紙幣短手搬送のタイプである。

これらのいろいろな識別機能に対し、それらの多くの機能を満足する識別アルゴ

リズムが現在模索中である。なかでも紙幣の搬送速度と識別機能は、相反するものである。比較的低速な搬送処理では、通常のパターンマッチング手法を用いており、基準パターンを作成し、これと評価紙幣のパターンを照合して、最も一致度の高いものを判定パターンとしている。また、比較的高速な搬送処理では、独自の分離関数を考案し、設計者のノウハウ、経験、一部の統計解析などに基づいて、その分離関数のパラメータを決定している。この分離関数は、基本的には加算、減算、比較の演算子を用いて、紙幣の特徴を表現したもので、パターンマッチング手法に比べて演算量は少ない。また、これらの識別演算を制御しているCPUは、比較的低速な搬送処理の場合よりも、大きなビット数のものが使用されており、ハードウェア面からも高速化に対応している。このように現在採用されている識別手法では、基準パターンの作成や分離関数のパラメータ決定において、大量の紙幣データ（数百万枚）を必要としている。さらに、基準パターンを作成する場合の紙幣の特徴量の抽出法、ならびにこれら識別手法の市場における汎化能力の検証などに関しては、まだ多くの問題点を残している。




Fig. 3.1 Sensor layout and sampling method.

つぎに、識別機が採取する紙幣データに着目すると、搬送によるノイズを含んだものになっている。つまり、紙幣識別機における採取データのばらつき E_1 は次式で与えられる。

$$y = y(E_1, h)$$

$$E_1 = E_1(e_1, e_2, e_3, e_4, e_5) \quad (3.1)$$

ただし、 y ：紙幣データ、 h ：真の紙幣データ、 e_1 ：紙幣の印刷ずれ、 e_2 ：センサ変動によるばらつき、 e_3 ：紙幣搬送中の起伏によるばらつき、 e_4 ：搬送系に対する紙幣のサンプルずれ、 e_5 ：搬送中の紙幣の伸びを示す。

$y(\cdot)$ 、 $E(\cdot)$ は、 (\cdot) の関数であることを示している。このうち搬送による採取データのばらつきは、 $e_3 \sim e_5$ である。 e_1 は他の e_i ($i=2, \dots, 5$) と比較してほとんど無視できるものである。そこで、以後(1)式の E_1 を次式の E で近似して取り扱うものとする。

$$E = E(e_2, e_3, e_4, e_5) (\approx E_1) \quad (3.2)$$

実際の紙幣データの時系列波形は、上述のばらつき E に起因して、Fig. 3.1 に示すような不均一な幅を有している。ばらつき E が小さくなれば、時系列波形も一本の折れ線に近付くことは明らかである。逆に、このばらつき E が大きければ大きいほど、紙幣の特徴をばかしてしまい、分離能力を低下させることとなる。

以上の状況下で、紙幣識別機の開発においては、製品開発の期間短縮や、紙幣の改札および高額紙幣の発行などに対して、従来の識別アルゴリズムとその開発手法では、市場への製品のタイムリーな供与がむずかしくなりつつある。そこで、本章では、NNの紙幣識別への応用可能性を、識別アルゴリズムの学習による自己組織化とその識別能力の点から考察する。

3.3 NNによる紙幣識別機構

本章で提案する紙幣識別用NNは、Fig. 3.2 に示すような3層構造である。すなわち、入力層はサンプル画素数128 (32サンプル×4センサ) と同じユニット数であり、隠れ層は、8ないし16ビットのCPUを有するハードウェアへの実装を考慮し、NNの構造を簡単にし、かつ非線形分離を可能にするために1層とする。また、隠れ層に含まれるユニット数に関しては、ユニット数をそれぞれ12, 24, 32, 64, 80として学習を行う。さらに、オーバーフィッティングの問題を考慮しつつ、NNの収束状況および識別性能を評価する。それらの結果を基にして、識




Fig. 3.2 Neural network for bill money recognition.




Fig. 3.3 Direction of conveyed bill money.

別性能が高くかつユニット数が少ないような隠れ層のユニット数として、入力画素数の $1/2$ である 64 を選定した。ただし、入力画像のグレイレベルは 1 バイト、すなわち、0 から 255 である。また、出力層は判定パターンを表わし、12 ユニットのする。本章では、偽造紙幣などを含む非紙幣を、識別の対象としているのではなく、真の紙幣を識別の対象としており、その識別の種類は 1 万円、5 千円、千円の 3 金種とその表、裏さらにその正立、倒立としている。したがって、判定パターン数は、1 万円、5 千円、千円のそれぞれの金種に対し、表正立、表倒立、裏倒立、裏正立の 4 搬送方向の合計 12 パターンとなっている。具体的に搬送方向の 4 パターンを Fig. 3.3 に示す。記述を簡略化するために、表正立、表倒立、裏倒立、裏正立を、それぞれ、A、B、C、D 方向と以後略記する。

なお、隠れ層と出力層の各ユニットは、出力関数 f としてシグモイド関数 $f(i) = 1 / (1 + \exp(-i))$ を使用する。

3.3.1 時系列データの入力

紙幣時系列データを直接に NN の入力とする場合、NN の識別機構入力部の構成は、Fig. 3.2 に示すような紙幣データから入力層への構成の部分と同じになる。なお、この入力データは、式 (3.2) で示されるばらつき E を含んでいる。

3.3.2 フーリエ係数の入力

紙幣の時系列データは、搬送とセンサ変動によるばらつき E を含んでいることをすでに述べた。しかるに、これらの時系列データにフーリエ変換¹⁵⁾を施せば、時間領域での情報を周波数領域で検討することが可能である。

とくに、時間領域における紙幣データにおいては、その真のデータと式 (3.2) で示すような種々のばらつきが混在した形で観察され、そのまま NN へ入力される。しかしながら、周波数領域における紙幣データにおいては、紙幣の真のデータと上述のばらつきが、周波数領域では、それぞれ、ある程度離れた位置で観察されると予想される。したがって、この周波数領域の紙幣データを、NN へ入力した場合、各ユニットごとに、紙幣の真のデータと種々のばらつきとを、ある程度分離すること

に相当するため、NNの分離関数の形成においては、有効な情報になっていると思われる。本章で採用するフーリエ変換による前処理は、128（4センサ×32サンプル）画素の時系列データを入力として、式(3.3)により得られるフーリエ係数 $A(n)$ 、 $B(n)$ を用いるものである。

$$A(n) = 1/N \sum_{k=1}^N f(k) \cos\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=0, 1, 2, \dots, N/2-1, N/2) \quad (3.3a)$$

$$B(n) = 1/N \sum_{k=1}^N f(k) \sin\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=1, 2, \dots, N/2-2, N/2-1) \quad (3.3b)$$

ただし、 $f(k)$ ：紙幣データ、 N ：データ数、 $A(n)$ 、 $B(n)$ ：フーリエ係数を示す。なお、 $f(k)$ のフーリエ変換を $F(n)$ とおく。すなわち、 $F(n)=A(n)+jB(n)$ とする。

以上の推測をシミュレーションによって確認するため、Fig. 3.4(a)に正弦波 $y=12.8 \sin(2\pi/32 \cdot i) (i=1, 2, \dots, 32)$ の時間領域の波形と、これを式(3.3a)、(3.3b)によってフーリエ変換した場合の周波数領域の波形を示す。ただし、正弦波曲線には、乱数幅がそれぞれ ± 5 、 ± 10 、 ± 20 、 ± 30 の一樣乱数によるノイズを付加している。Fig. 3.4(a)より正弦波曲線の特徴づける情報は、低周波帯域に存在し、ノイズは点線で示された値より、高周波帯域に存在することは明かである。

つぎに、実際の紙幣データについて同様の確認を行う。ここでは、データの代表として、それぞれの金種のA方向の第一センサから得られる32個のデータ（各10枚分）を例にとり、時間領域と周波数領域のデータをFig. 3.4(b)に示す。ただし、図中の点線は信号成分とノイズ成分を区別する近似的な境界線を示している。Fig. 3.4(b)から明かなように、Fig. 3.4(a)のノイズを付加した正弦波曲線と同様に、式(3.2)で示されるような種々のばらつきが、高周波帯域に存在する傾向があることが観察される。このように、紙幣データにフーリエ変換を施すことにより、得られるデータの表現が、NNによる紙幣識別により適合すると予想される。

Fig. 3.5は、本章で考察するフーリエ変換を前処理とする、NNによる識別機構の入力部の構成を示している。




Fig. 3.4 Sensor data and its Fourier coefficients.




Fig.3.5 Input of Fourier coefficients.

3.4 紙幣識別実験

ここでは、時系列データおよびフーリエ係数を用いた教師付き学習によるNNの紙幣識別実験と、その結果について考察する。

3.4.1 紙幣識別機データ

ここで行う識別実験で使用する紙幣データは、現在すでに製品化されている紙幣短手搬送、高速処理識別機（8枚以上/秒）から採取したものである。この識別機のセンサは、4個であり、それらの設置場所は、経験的に最も紙幣の特徴を捕らえることができるようにレイアウトされている。ここで、これらのすでに製品化されている紙幣識別機に対し、NNを用いた紙幣識別アルゴリズムを、ソフトウェアまたは、ハードウェアの形で移植することを前提として検討を行う。

3.4.2 シミュレーション条件

まず、学習アルゴリズムは、通常のバックプロパゲーション法¹⁶⁾に、慣性項と振

動項を付加する¹⁷⁾。慣性項は、収束を早める働きを有し、振動項は、解の探索をローカルミニマムから脱却させる働きを有している。慣性項と振動項を付加した学習アルゴリズムは、次式で与えられる。

$$\Delta W_{ij}^{k-1k} = -\varepsilon d_j^k \cdot o_i^{k-1} + \alpha \Delta W_{ij}^{k-1k} + \beta \Delta W_{ij}^{k-1k} \quad (3.4)$$

ただし、 ΔW ：重みの修正量、 d ：一般化誤差、 o ：出力、 t ：繰り返し回数、 ε ：正の学習定数、 α ：慣性項の比例定数、 β ：振動項の比例定数を示す。

また、 ΔW_{ij}^{k-1k} は $k-1$ 層の i ユニットから k 層の j ユニットへの重みの修正量を示し、 d_j^k は k 層の j ユニットの一般化誤差、 o_i^{k-1} は $k-1$ 層の i ユニットの出力を、それぞれ、

示す。さらに、 α および β は、Fig.3.6に示す関係を満たすように調整する¹⁷⁾。




Fig.3.6 Relation between α and β .

Fig.3.7は紙幣時系列データに対する慣性項と振動項を付加した収束効果を示している。なお、学習回数は、パターン1からパターン12までの教示をもって1回とする。また、重みの修正は、各パターン提示ごとに行う。ここでは、Fig.3.7に示すように種々の試行錯誤の後に、 $\varepsilon, \alpha, \beta$ を、それぞれ、 $\varepsilon=0.1, \alpha=0.9, \beta=-0.1$ として設定した。ただし、ここでは、各パターン提示ごとに得られる出力層のユニットの出力値と、教師値との差の平方和の $1/2$ を、パターン1からパターン12まで合計した値が0.001以下になるとき学習は収束したと見なすものとする。




Fig.3.7 Convergence with various values of α and β where $\varepsilon=0.1$.

紙幣データを目視で観察する限り、紙幣を特徴づける各パターンは、式(3.2)で示されるばらつきによるパターンの乱れを受けた場合でも金種、方向の間で明確な差

異を有している。そこで、学習データに対するNNのオーバーフィッティングの危険性を回避し種々のデータに対する汎化能力を向上させる意味で、学習データとしては1万円、5千円、千円のそれぞれA、B、C、D方向の12パターンに対し、各10枚を使用する。これらの紙幣データをNNにパターン1からパターン12まで逐次的に提示する。

評価データのケース1は、(1)紙幣の通路幅の中心に、紙幣の中心を合わせて搬送させて採取した、3金種、4方向、各10枚の合計120枚とする。さらに、評価データのケース2は、(1)に加え(2)紙幣の通路幅の中心から紙幣の中心を、マイナス10mmずらせて搬送させて採取した、3金種、4方向、各10枚の合計120枚と、(3)紙幣の通路幅の中心から紙幣の中心を、プラス10mmずらせて搬送させて採取した、3金種、4方向、各10枚の合計120枚をすべて合計した360枚(ケース2)とする。ただし、ケース2で±約10mmずらせた紙幣データを評価データとして用いる理由は、(1)実際の紙幣識別機では種々の紙幣を同時に搬送可能としているため、紙幣サイズの差異により±約10mmのずれがあること、(2)センサ感度幅が約4mmであり、±約10mmのずれは汎化能力を検証するために十分であると思われることなどである。

3.4.3 収束状況の比較

Fig.3.8は、(1)NNに紙幣の時系列データを入力した場合と(2)時系列データをフーリエ変換し、そのフーリエ係数をNNに入力した場合に対して、収束判定誤差が0.001に至るまでの収束状況を示している。ただし、学習データはケース1と同様な搬送状態のデータを使用した。Fig.3.8の結果から分かるように、上述の(1)の場合には、収束に至る回数が4650回、また(2)の場合には、3590回の学習回数が必要であった。したがって、フーリエ係数をNNに入力した場合の方が、時系列データを入力する場合より、約23%だけ早く収束している。このことは、フーリエ変換を用いることにより、搬送系に対する紙幣のずれ e_4 や紙幣の伸び e_5 の影響が軽減され、入力データの分離がより容易になっているためである。このように物理事象に固有の特徴を抽出するようなデータの前処理を行い、分離が容易となるデータをNNの入力として利用することが、応用上有効な手法である。




Fig. 3.8 Comparison of convergences with FFT and without FFT, respectively.

3. 4. 4 鑑別率の比較

ここでは、識別性能の評価規範として、従来から用いられている鑑別率（統計的確率）^{12), 13)}を使用する。鑑別率 ES_1 は、次式で与えられる。

$$ES_1 = \frac{\Delta \text{ 正しく認識された事象の個数}}{\text{全事象の評価個数}} \times 100 (\%) \quad (3.5)$$

Fig. 3.9 に 3 金種、4 方向各 10 枚（ケース 1）と 3 金種、4 方向各 30 枚（ケース 2）の鑑別率の比較を示す。比較アルゴリズムは、(1) パターンマッチング識別手法、(2) NN による識別手法、および (3) フーリエ変換を前処理として利用した NN による識別手法のそれぞれの場合に対して考察する。ここで比較のために採用する

パターンマッチング識別手法は、次式で与えられる。これは、8 ないし 16 ビットの CPU を有する、実際の製品に応用されている手法の一つであり、その識別部の一部を抽出したものである。ただし、製品においては、この比較識別手法は、入力データのノイズ除去ならびに正規化などの種々の前処理により、市場における十分な識別性能（8 枚以上／秒）と信頼性を維持している。

$$R_j \triangleq \frac{\sum_{i=1}^{32} |x_i^j - \bar{x}_j|}{\max_i (|x_i^j - \bar{x}_j|)} \times 100 (\%) \quad (j=1, 2, 3, 4) \quad (3.6)$$

ただし、 R_j : 紙幣代表ベクトル、 x_i^j : 紙幣時系列データ、 \bar{x}_j : 紙幣時系列データの平均値、 $\max_i (|x_i^j - \bar{x}_j|)$: 時系列データの平均からの最大起伏を示す。

紙幣の識別は、基準パターン R_j ($j=1, 2, 3, 4$) および評価パターン R_j^* ($j=1, 2, 3, 4$) で距離 L をつぎのように算出し、 $L = \left(\sum_{j=1}^4 (R_j - R_j^*)^2 \right)^{1/2}$ が最小距離を有するパターンを判定パターンとする⁵⁾。




Fig. 3.9 Comparison of pass ratio.

3 金種, 4 方向ごとに 12 パターンの出力が得られるが, 評価結果の理解を容易にする意味から, 金種内の最悪値を金種の代表値とした鑑別率 ES_1 を用いることとする。たとえば, 1 万円の A 方向 = 100%, 1 万円の B 方向 = 98%, 1 万円の C 方向 = 99%, 1 万円の D 方向 = 100% であれば, 1 万円の鑑別率は最悪値の 98% とする。

まず, パターンマッチング手法と比較して, NN を用いた識別手法が, 識別性能の点で優れていることが, Fig. 3.9 の実験結果から定量的に示されている。つぎに, Fig. 3.9 から分かるように, 時系列データを入力とする場合と, フーリエ係数を入力とする場合の各々に対して, NN による識別性能は, ケース 1 ではどちらも同じである。しかし, 搬送において紙幣をずらせたケース 2 の場合においては, フーリエ変換を用いてデータを前処理することで, 1 万円, 5 千円, 千円の鑑別率は, それぞれ, 87% から 100%, 70% から 87%, 47% から 67% となり, Fig. 3.9 に識別性能が向上可能であることが示されている。

3. 5 信頼性評価

3. 5. 1 従来の評価規範の問題点

従来, NN を用いたパターン認識においては, その性能評価を, 統計的確率である鑑別率 ES_1 だけで行っている^{12), 13)}。つまり, NN の出力ユニットの出力値に対して, その最大値のみが評価の対象となっている。しかしながら, このような評価指標では, 最大値以外の出力値で最大値にかなり近い値であっても評価結果には直接的な影響が反映されていない。たとえば 3. 4 節の 3 金種, 4 方向各 10 枚のケース 1 の評価において, 時系列データを使用した場合も, フーリエ係数を使用した場合も, NN による鑑別率の結果は, いずれも 100% である。しかし, それらの NN における出力値は以下の値となっている。

c 1 (0.95, 0.01, 0.00, 0.01, 0.00, 0.00, 0.00, 0.01, 0.00, 0.00, 0.00, 0.01)

c 2 (0.99, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00)

ただし, * は最大値を示し, ** は 2 番目に大きい値を示す。ここで, c 1 は時系

列データを NN に入力した場合の出力層のユニット値を示し, c 2 はフーリエ係数を NN に入力した場合の出力層のユニット値を示す。このデータから最大値とその次に大きい値との差が c 1 の場合には, 0.94, c 2 の場合には, 0.99 であり, 分離度の見地から見れば, c 2 の方がより優れていることが容易に理解できる。

一般に, 産業界で NN を応用した製品においては, 出力ユニットの最大値のみならず, 最大値以外の出力値が, 最大値から十分離れていることが要求されている。なぜならば, 市場においては外部の影響で, 入力データにノイズが混入した場合や, センサ系の劣化により感度がばらついた場合でも, その出力結果が, 正常な製品による出力結果に可能な限り近いことが要請されているからである。つまり, 出力ユニットの最大出力値とそれ以外の出力値が互いに近い状態の製品よりも, 十分に離れた距離の出力を与える製品の方が望まれている。

鑑別率 ES_1 のみで, このような評価を行うには不十分であり, この問題を考察するために以下では信頼性の評価規範を新たに導入する。

3. 5. 2 信頼性評価規範

ここでは, NN による識別結果が, どの程度の信頼性を有しているかを示す指標として, 信頼性評価規範を導入する。

まず, ある入力に対しパターン 1 からパターン 12 に対応した出力値が NN の出力ユニットから得られることに注目する。本章での識別判定は, この出力値の最大値を有するユニットのパターンを抽出する方法¹³⁾を採用している。しかしながら, この各出力ユニットの値に着目すると, 最大値とそれ以外の値との差を識別判定のための分離距離と見なすことが可能である。この分離距離を用いることによって, 識別判定に対する信頼性を定量的に評価することができる。さらに, N 個の同一パターンに対する入力を与えれば, それに対応する出力ユニット値は, あるばらつきを有する確率分布に従うことになる。したがって, Fig. 3.10 に示すように, 同一パターンの入力に対する出力ユニットの値の分布を求め, 目的パターンと排除パターンとの分布のクロスする上側確率を求める。ただし, 出力ユニット値の分布形が判明しなければ上記の上側確率を求めることは不可能である。しかるに, 本章で考察する信頼性評価規範は, この上側確率の値そのものを論議するのではなく, それぞ

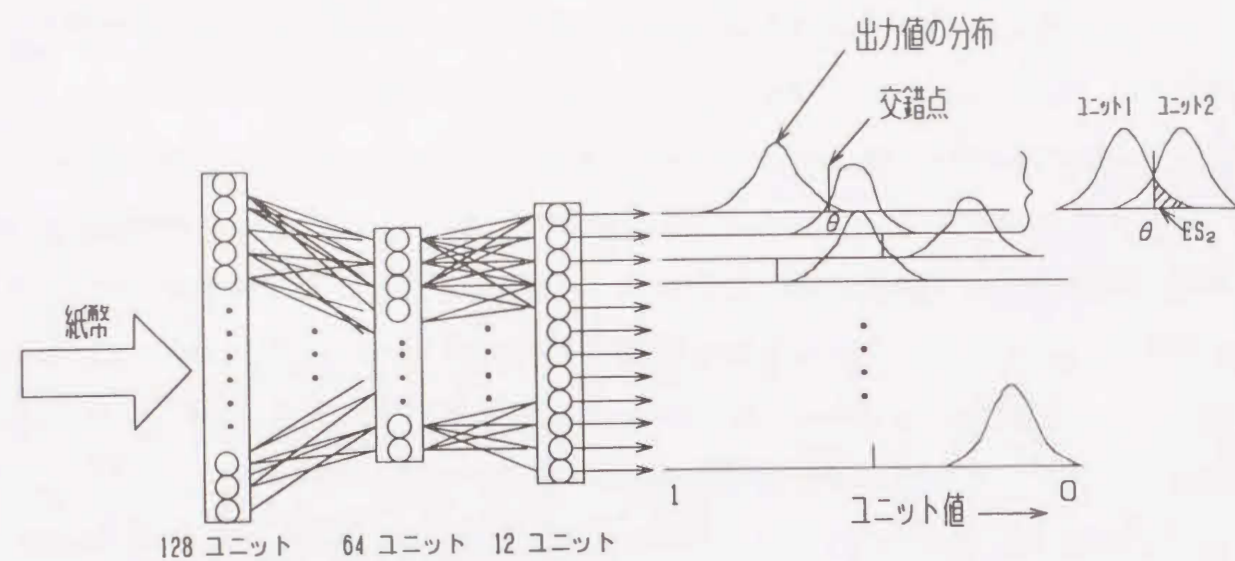


Fig.3.10 Distribution of output values.

れの識別手法の相対評価を行うため、出力ユニット値の分布を平均値 μ 、標準偏差 σ の正規分布 $N(\mu, \sigma^2)$ と仮定する。この理由は、本仮定を用いた場合の種々の識別手法の優劣関係が、出力ユニット値の真の分布を用いた場合の識別手法の優劣関係で略近似されるからである。

したがって、ここでは、出力ユニット値の分布が、正規分布であるという仮定のもとで、目的パターンが誤識別される事象の生じる確率、つまりこの場合の上側確率を信頼性評価規範として定義する。それゆえ、信頼性評価規範 ES_2 は式(3.7)で与えられる。

$$ES_2 = \Delta \int_{\theta}^{\infty} \frac{1}{(2\pi)^{1/2} \sigma_p} \exp\left(-\frac{(x - \bar{x}_p)^2}{2\sigma_p^2}\right) dx \quad (3.7)$$

ただし、 σ_p : 目的パターンのデータの標準偏差、 \bar{x}_p : 目的パターンのデータの平均値、 x : 目的パターンの出力ユニットの値、 θ : 目的パターンのデータ分布と排除パターンのデータ分布との交点の x 座標を示す。

したがって、この信頼性評価規範 ES_2 を用いると、 ES_2 が小さい場合は、識別の信頼性が高いと判断することができる。

3.5.3 信頼性の比較

Fig.3.11は、3.4節の鑑別率 ES_1 の比較に対して用いた3金種、4方向各10枚(ケース1)と3金種、4方向各30枚(ケース2)の各々の場合に対する信頼性の比較を示している。ただし、Fig.3.11の縦軸は対数軸とし、 $-\log_{10} ES_2$ を示している。比較アルゴリズムは、鑑別率 ES_1 の比較の場合と同様に、(1)パターンマッチング手法、(2)NNによる識別手法および(3)フーリエ変換を前処理としたNNによる識別手法とする。




Fig.3.11 Comparison of reliability.

3 金種、4 方向の 1 2 パターンに対し、 $P_2=1\ 3\ 2$ の通りの結果が得られる。しかし、鑑別率と同様に、結果の理解を容易にするために、金種内の信頼性評価規範 ES_2 の最悪値を金種の代表値として選定し、その信頼性を検討する。信頼性においても鑑別率と同様に Fig. 3.11 から分かるように、(1) パターンマッチング識別手法より (2)、(3) の NN を用いた識別手法の方が、識別性能の点で優れている。

さらに、ケース 1 の場合、鑑別率評価では、NN による識別手法と、フーリエ変換を前処理とする NN による識別手法との間で性能差が認められなかった。しかるに、Fig. 3.11 から分かるように、信頼性評価規範 ES_2 に基づいた評価法では、それぞれの手法の性能差が明確に認められる。したがって、NN を用いたパターン認識システムの信頼性を評価するために、本章で提案した信頼性評価規範 ES_2 を導入することの妥当性が示された。とくに、産業界で、NN を用いた製品を市場に送り出す場合においては、鑑別率のみならず、信頼性の高い製品を送り出すことが必要であり、ここで導入した ES_1 、 ES_2 の意義も大きくなると思われる。

3. 6 おわりに

本章では、搬送によるノイズの影響が大きい高速搬送機から採取される紙幣データに対して、NN を用いた識別手法の有効性を実験により定量的に検証した。また、紙幣の時系列データにフーリエ変換を施すことにより、得られるデータの表現が、NN による紙幣識別に適合し、識別性能が向上することをシミュレーション実験により定量的に検証した。さらに、NN によるパターン認識の性能評価規範として、従来から採用されていた統計的確率（鑑別率）のほかに、信頼性評価規範を新たに導入した。この信頼性評価規範を導入することで、NN の結果に対する信頼性を考察することができ、産業界での NN の応用を、より一層促進できるものと思われる。なお、本章ではフーリエ係数をすべて利用した NN を構成したが、フーリエ係数の中で重要な係数を選択して NN を構成することも考えられる。

さらに、フーリエ係数を直接 NN に入力すると、サンプルずれの影響が、フーリエ係数の各周波数成分に混入することが多くなる。このことについては、フーリエ係数の振幅成分のみを NN へ入力すれば、サンプルずれの影響を除去することが可能であり、この点に関しては、次の第 4 章で詳細に検討する。

また、本章で構成した紙幣識別用 NN の計算量は、現在製品において採用されている識別アルゴリズムの計算量の約 4 倍程度となっている。したがって、今後、8 ビットあるいは 16 ビットの CPU で、現製品と同等の紙幣処理速度（8 枚以上／秒）を実現するには、アルゴリズムの面から NN の規模の縮小化が必須となる。これについては、認識画像の代表値として、スラブ値を NN へ入力する方法^{1.11), 1.13)}が考えられ、これに関しては以後の第 5 章、6 章で詳述する。

第4章 ニューラルネットワークを用いた 高速搬送紙幣の識別

4.1 はじめに

第3章では、フーリエ変換を用いたNNによる紙幣識別の有効性を述べたが、データのサンプルずれの影響が周波数成分に混入する問題点が未解決であった。ここでは、フーリエ係数の振幅成分をも含めたNNによる紙幣識別を考察する。これにより、フーリエ変換をNNの前処理機構とすることの有効性を、すでに第2章で述べた高速搬送機で用いられる識別式による紙幣識別手法と比較検討し示す。

また、前章で導入した信頼性評価規範を用い、フーリエ係数を用いたNNによる紙幣識別手法の信頼性評価に加えて、フーリエ係数の振幅および選択的なフーリエ係数の振幅を用いたNNによる紙幣識別手法の信頼性評価についても検討する。

最後に、紙幣の時系列データを用いたNNによる識別手法、そのフーリエ係数を用いたNNによる識別手法、さらにフーリエ係数の振幅を用いたNNによる識別手法の各手法におけるNNの出力層のユニット値の分布をヒストグラムで表現し、視覚的に各手法の優位差を確認する。

4.2 紙幣識別の概要と問題点

製品化されている紙幣識別機においてそのセンサは、Fig. 4.1に示すように紙幣の特徴を最も代表する部分をセンシングできるようにレイアウトされている。Fig. 4.1内の波線の矩形は、個々のセンサが紙幣の搬送によりセンシングする領域を示している。識別機は、このように採取されるデータに基づいて紙幣の識別を行っている。一般に、紙幣識別機は、識別機能で見ると、上位機種は金種と搬送方向、紙幣の汚れ、穴あき、破れなどの判定から、下位機種は金種のみ判定までの広範囲にわたっている。また、識別機への紙幣の挿入方法により紙幣長手搬送と紙幣短手搬送の二種類に分類される。さらに、紙幣の搬送速度の点では、前述したような10枚/秒の高速処理から1枚/秒の通常処理に至る機能を有する識別機が製品化されてい

る。とくに、高速処理に属するのは、ほとんどが紙幣短手搬送のタイプである。これらのいろいろな識別機能と処理速度に対し、それぞれに最適な識別アルゴリズムが機種毎に開発されている。たとえば、比較的低速な搬送処理では、通常のパターンマッチング手法を用いており、基準パターンを作成し、これと評価紙幣のパターンを照合して、最も一致度の高いものを判定パターンとしている。また、比較的高速な搬送処理では、独自の分離関数を考案し、設計者のノウハウ、経験、一部の統計解析などに基づいてその分離関数のパラメータを決定している。この分離関数は、基本的には加算、減算、比較演算を行って紙幣の特徴を表現したものであり、パターンマッチング手法に比べ演算量は少なく、高速処理を可能としている。また、これらの識別演算を制御しているCPUは比較的低速な搬送処理の場合よりも大きなビット数のものが使用されており、ハードウェア面からも高速化に対応している。現在採用されているこのような識別手法においては、基準パターンの作成や分離関数のパラメータ決定において大量の紙幣データ（数百万枚）と数カ月に及ぶ開発期間を必要としている。さらに、市場における紙幣識別機の経年変化による識別率の変動、および、流通紙幣の疲弊や予期せぬ雑音などによる識別率の変動に対して識別アルゴリズムを必要以上に強化する必要がある。さらに、紙幣の改札および高額紙幣の発行などに対し、従来の識別アルゴリズムとその開発手法では、市場への製品のタイムリーな供与が困難になりつつある。




Fig. 4.1 Sensor layout and sampling method.

以上の状況下で、紙幣識別機の開発における最優先課題は、製品開発の期間を短縮することである。そこで本章では、NNを紙幣識別に応用し、その識別能力を評価するとともにその識別アルゴリズムの自己組織化による開発期間短縮について考察する。




Fig.4.2 Construction of NN for bill money recognition.




Fig.4.3 Direction of conveyed bill money.

4.3 NNによる紙幣識別機構

本章で提案する紙幣識別用NNはFig.4.2に示すような3層構造である。入力層は1バイトの濃淡画像で128画素(32サンプル×4センサ)の情報を直接あるいは以後で述べるFFTの処理後に受け取る。隠れ層は、入力画素数の1/2である64ユニットに固定している。隠れ層の層数とユニット数は種々のシミュレーションで決定する。また、出力層は判定パターン数を表わし、12ユニットとする。つまり本章では、識別の単位を1万円、5千円、千円の3金種とその表、裏さらにその正立、倒立としいる。したがって、判定パターン数は、1万円、5千円、千円のそれぞれの金種に対し、表正立、表倒立、裏倒立、裏正立の4搬送方向となり、合計12パターンとなっている。具体的に搬送方向の4パターンをFig.4.3に示す。以後、第3章のように搬送方向の表正立、表倒立、裏倒立、裏正立を、それぞれ、A、B、C、D方向と略記する。

4.3.1 時系列データの入力

本章で取り扱う識別機で採取する紙幣データ y は、種々の雑音を含むため次式で与えられる。

$$y = y(E, h) \\ E = E(e_1, e_2, e_3, e_4) \quad (4.1)$$

ただし、 y ：紙幣データ、 h ：真の紙幣データ、 e_1 ：センサ変動によるばらつき、 e_2 ：紙幣搬送中の起伏によるばらつき、 e_3 ：搬送系に対する紙幣のサンプルずれ、 e_4 ：搬送中の紙幣の伸びを示す。

また、 $y(\cdot)$ 、 $E(\cdot)$ は (\cdot) の関数を意味する。このうち搬送による採取データのばらつきは、 $e_2 \sim e_4$ である。とくに、 e_3 は、紙幣一枚毎の搬送速度が微妙に異なるために発生するものである。また、雑音として紙幣の印刷ずれも考えられるが、実際には他の $e_i (i=1, \dots, 4)$ と比較してほとんど無視できるため、ここでは省略する。したがって、採取する紙幣データは、紙幣データそのものと式(4.1)で与えられる E が混合されたものである。以後、紙幣データ(センサ値)を紙幣次系列デ

ータとして取り扱う。1万円紙幣の表正立を例にとり、実際に採取された紙幣データをFig.4.4に示す。同図に示すように、上述のばらつきEに起因して時系列データは、不均一な幅を有している。このばらつきEが小さくなれば、時系列データも一本の折れ線に近付き識別し易くなることは明らかである。ここでは、まずこの時系列データを直接NNに入力し、その識別能力を考察する。この場合、入力ユニット数は、画素数と同じ128となる。




Fig.4.4 Time series data for ¥10,000.

4. 3. 2 フーリエ係数の入力

紙幣の時系列データは、搬送とセンサ変動によるばらつきEを含んでいることをすでに述べた。しかるに、これらの時系列データにフーリエ変換¹⁵⁾を施せば、時間領域での情報を周波数領域で検討することが可能である。本章で採用するフーリエ

変換による前処理は、128画素の時系列データを入力として、式(4.2)により得られるフーリエ係数A(n), B(n)を用いるものである。

$$A(n) = \frac{1}{N} \sum_{k=1}^N f(k) \cos\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=0, 1, 2, \dots, N/2-1, N/2)$$

(4.2)

$$B(n) = \frac{1}{N} \sum_{k=1}^N f(k) \sin\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=1, 2, \dots, N/2-2, N/2-1)$$

ただし、f(k):紙幣データ、N:データ数、A(n), B(n):フーリエ係数を示す。なお、f(k)のフーリエ変換をF(n)、すなわち、F(n)=A(n)+jB(n)とする。




Fig.4.5 Fourier coefficients A, B for ¥10,000.

(1) フーリエ係数の入力

ここでは、Fig. 4.5に示すように1万円紙幣を例にとり、複数紙幣データを上述の式(4.2)によってフーリエ変換したフーリエ係数A,Bと時系列データのばらつきを比較する。時系列データの各サンプルに対する最大標準偏差の平均値は、本実験では、1万円、5千円、千円のそれぞれに対して、28.6, 29.5, 27.8である。これに対してフーリエ係数の各周波数に対する最大標準偏差の平均値は、1万円、5千円、千円のそれぞれに対して、3.51, 3.68, 2.65である。このように、紙幣時系列データのばらつきEは、周波数領域では小さく表現されており、NNにとってはより安定した入力になっている。そこでまず、この128個のフーリエ係数を直接NNに入力する。したがって、入力層のユニット数は128となる。

(2) フーリエ係数の振幅の入力

(1)で紙幣の時系列データをフーリエ変換することにより、そのデータのばら




Fig. 4.6 Amplitude for Fourier coefficients $(A^2+B^2)^{1/2}$ for ¥10,000.

つきを1/8以下に小さく表現できることを述べた。しかしながら、厳密には e_3 , e_4 などのサンプルのずれによる誤差はフーリエ係数A,Bの位相成分に残っている。それゆえに、完全に時間方向のずれを除去するためには、Fig. 4.6の1万円紙幣の表正立の例に示すような、フーリエ係数A,Bの振幅 $(A^2+B^2)^{1/2}$ をNNに入力する必要がある。確認のため、フーリエ係数A,Bとその振幅 $(A^2+B^2)^{1/2}$ の各周波数に対する最大標準偏差の平均値を比較すると、本実験では、1万円、5千円、千円のそれぞれに対して、3.51, 3.68, 2.65, および3.12, 3.28, 1.91である。このように、紙幣時系列データの周波数の振幅成分は時間方向のずれの影響を受けないことになり、NNにとってはさらに安定した入力になると思われる。ここでは、このフーリエ係数の振幅をNNに入力する。この場合、各々のセンサから32画素のデータが得られ、センサ毎にフーリエ変換すると式(4.2)で示すように係数Aは、17個、係数Bは15個となる。それゆえ、振幅は17個 $\{|A(0)|, (A(1)^2+B(1)^2)^{1/2}, \dots, (A(15)^2+B(15)^2)^{1/2}, |A(16)|\}$ となり、入力層のユニット数を68 (17×4) とした。

4. 4 紙幣識別実験

ここでは、時系列データおよびフーリエ係数さらに、フーリエ係数の振幅を用いた教師付き学習によるNNの識別実験とその結果について以下で考察する。

4. 4. 1 紙幣識別機データ

これまでに製品化されている識別機においては、前述した固有の紙幣分離関数を使用して識別処理の高速化を図っている。しかしながら、この分離関数の開発には、数カ月の作業工数と3年以上の経験が必要としている。これらの工数を軽減し、専門家の経験の抽出に対し、エキスパートシステムが有効であることはすでに第2章で述べた。

本章は、人間の有している優れたパターン認識能力に着目し、上述の紙幣識別手法として新たにNNを応用するものである。ここで行う識別実験で使用する紙幣時系列データは、現在すでに製品化されている紙幣短手搬送の高速処理識別機(8枚/秒以上)から採取したものである。この識別機のセンサは、処理速度とデータ量

の制約から4個に固定されており、それらの設置場所は経験的に最も紙幣の特徴を捕らえることができるようにレイアウトされている。

4. 4. 2 従来の紙幣識別手法

従来の高速処理機の紙幣識別は、前述したように独自の分離関数である識別式を用いて行われている。この設計者による紙幣識別のための識別式を決定する作業は以下のようになっている。まず、紙幣を識別するためのポイント（識別点）群を各種センサの紙幣時系列データから抽出する。抽出された識別点群より特徴抽出関数

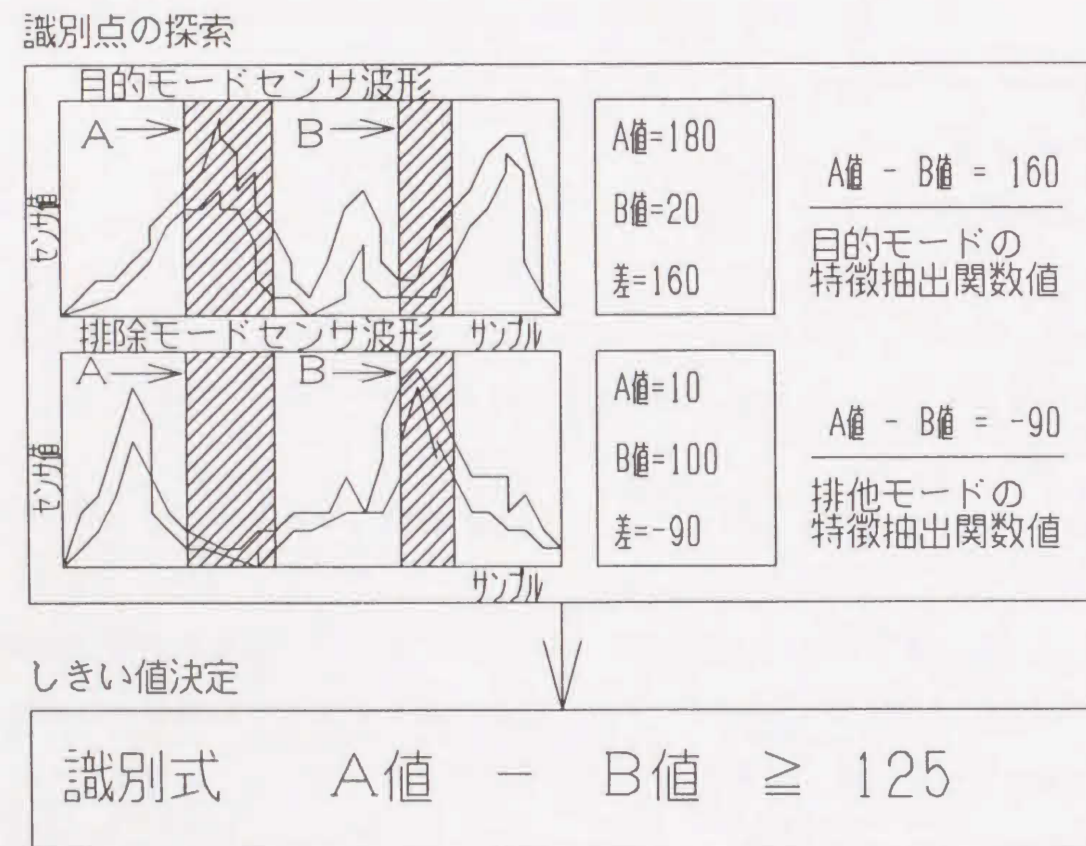


Fig. 4.7 Decision of discriminative function by use of sensing data.

（この場合は、ある点列の合計から別の点列の合計を差し引く演算）を決定し、この関数により得られる紙幣代表値を用いて識別式（特徴抽出関数にしきい値を付加して不等式としたもの）を決定する。この識別式をパターン毎に複数個作成し、入

力データを評価して全ての識別式が成立するパターンを判定パターンとしている。なお、識別点の位置と個数、識別式数は設計者の経験と試行錯誤により決定されている。Fig. 4.7は、紙幣時系列データと、識別点、それに識別式の関係を示しており、横軸はサンプル、縦軸はセンサ値である。また、同図の識別点の探索は、識別紙幣である目的モードと被識別紙幣である排除モードの識別点群（A、B）と特徴量抽出関数によるそれぞれの紙幣代表値（A値、B値）を表わしている。この場合、目的モードの時系列データから、センサ値の平均値を用いるとA値-B値として160が得られる。一方排除モードからは同様にA値-B値として-90が得られる。したがって、しきい値を仮に125に設定すると目的モードと排除モードが分離できる。

4. 4. 3 シミュレーション条件

学習アルゴリズムは、通常的一般化バックプロパゲーション法¹⁶⁾に慣性項と振動項を付加する^{17), 20)}ものである。ここで、慣性項は、収束を早める働きを有し、振動項は、解の探索をローカルミニマムから脱却させる働きを有している。慣性項と振動項を付加した学習アルゴリズムは、次式で与えられる。

$$\Delta W(t) = -\varepsilon d_{i,j}^{k-1,k} + \alpha \Delta W(t-1) + \beta \Delta W(t-2) \quad (4.3)$$

ただし、 ΔW ：重みの修正量、 d ：一般化誤差、 o ：出力、 t ：サンプル、 ε ：正の学習定数、 α ：慣性項の比例定数、 β ：振動項の比例定数、 i, j ：ユニットの指定子、 k ：層の指定子を示す。

また、 $\Delta W(t)$ は $k-1$ 層の i ユニットから k 層の j ユニットへの重みの修正量を示し、 $d_{i,j}^{k-1,k}$ は k 層の j ユニットの一般化誤差、 o_i^{k-1} は $k-1$ 層の i ユニットの出力を示す。

なお、学習回数は、パターン1からパターン12までの教示をもって1回とする。重みの修正は、各パターンの提示毎に行う。収束判定は、各パターン毎に得られる出力層の値と教師値との差の2乗をパターン1からパターン12まで総和したものと収束判定値(0.001)との比較で行う。学習データは、1万円、5千円、千円のそれ

ぞれ A, B, C, D 方向の 12 パターンの紙幣データを各 1 枚使用する。これらの紙幣データを NN にパターン 1 からパターン 12 までシーケンシャルに提示する。評価データは、未学習の 3 金種、4 方向、各 10 枚の合計 120 枚とする。

4.4.4 鑑別率の比較

ここでは、識別性能の評価規範として従来から用いられている鑑別率（統計的確率）^{12), 13)} を使用する。鑑別率 ES_1 は、次式で与えられる。

$$ES_1 = \frac{\Delta \text{ 正しく認識された事象の個数}}{\text{全事象の評価個数}} \times 100 (\%) \quad (4.4)$$

Fig. 4.8 に 3 金種、4 方向各 10 枚の鑑別率の比較を示す。比較アルゴリズムは、(1) 高速処理機に採用されている識別式を用いた従来の識別手法、(2) 時系列データを用いた NN による識別手法、(3) フーリエ係数 A, B を用いた NN による識別手法、(4) フーリエ係数の振幅 $(A^2+B^2)^{1/2}$ を用いた NN による識別手法、(5) 第 1 周波数か

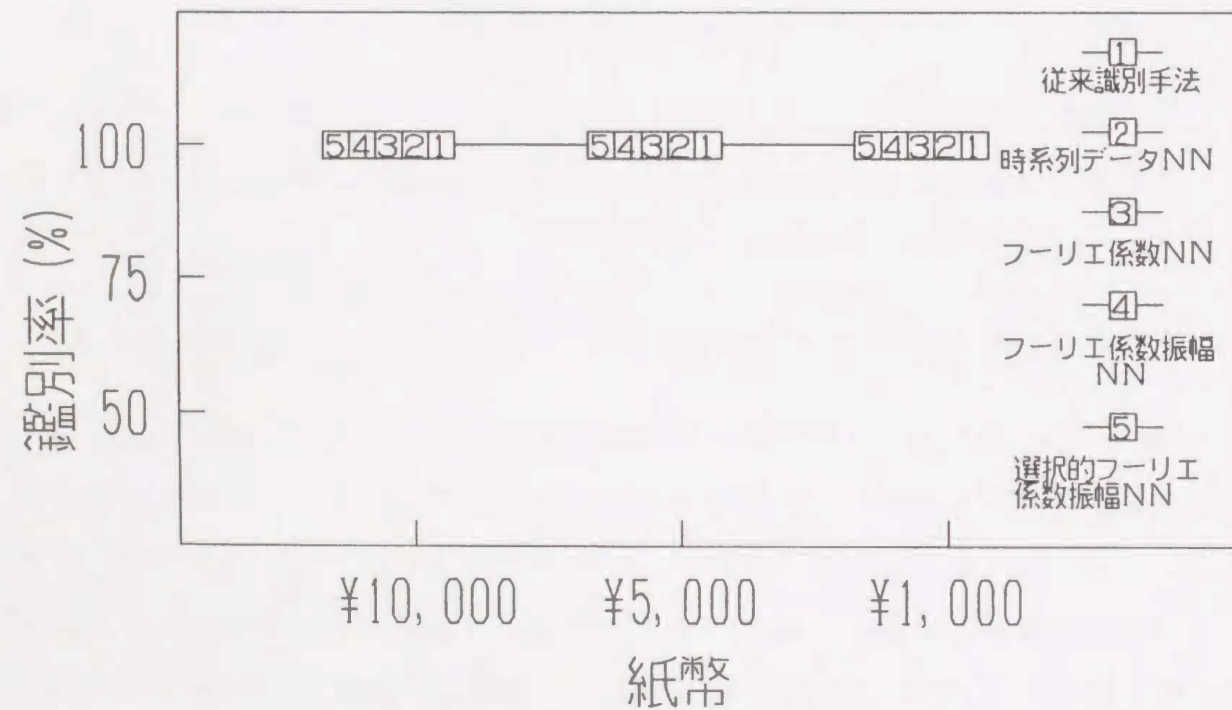


Fig. 4.8 Comparison of pass ratio.

ら第 9 周波数までのフーリエ係数の振幅を用いた NN による識別手法のそれぞれの場合に対して考察する。ここでは、3 金種、4 方向毎に 12 パターンの鑑別率が得られるが、評価結果の理解を容易にするために金種内の最悪値を金種の代表値とした鑑別率 ES_1 を用いることとする。たとえば、1 万円の A 方向 = 100%，1 万円の B 方向 = 98%，1 万円の C 方向 = 99%，1 万円の D 方向 = 100% であれば、1 万円の鑑別率は最悪値の 98% とする。まず、Fig. 4.8 の実験結果から従来の識別手法 (1) と比較して提示した全ての NN を用いた識別手法 (2) ~ (5) は、識別性能の点で同等の性能を得られることが定量的に示されている。さらに、従来手法 (1) では、その開発に 6 カ月以上を要しているが NN を用いた手法 (2) ~ (5) の場合には、NN の構成およびパラメータ決定に要する期間は、高々 1 カ月であり、NN を用いた識別手法が開発期間の点で紙幣識別に有効であることが示されている。しかしながら、さらに性能を詳細に検討するには、それぞれの手法の入力データのばらつきの違いによる鑑別率評価では表わしきれない潜在的な識別能力差を別の評価方法で明確にする必要があり、これについて以下で考察する。

4.5 信頼性の評価法

4.5.1 従来の評価規範の問題点

NN を用いたパターン認識においてこれまでは、その性能評価が統計的確率である鑑別率 ES_1 によって行われてきている^{12), 13)}。つまり、NN の出力ユニットの

Table 4.1 Comparison of output values on NN.

	1	2	3	4	5	6	7	8	9	10	11	12
時系列データ C ₁	* 0.954	** 0.011	0.002	0.010	0.003	0.002	0.000	0.010	0.001	0.002	0.000	0.005
フーリエ係数 C ₂	* 0.991	0.004	0.001	** 0.005	0.002	0.001	0.002	0.000	0.002	0.001	0.002	0.003
フーリエ係数 振幅 C ₃	* 0.989	0.001	0.004	** 0.005	0.001	0.000	0.002	0.000	0.003	0.000	0.001	0.005

出力値に対してその最大値のみが評価の対象となっている。しかしながら、このような評価指標では、最大値以外の出力値で最大値にかなり近い値であっても評価結果には直接的な影響が反映されていない。たとえば、4.4.4節の3金種、4方向各10枚の評価において時系列データを使用した場合(c1)、フーリエ係数を使用した場合(c2)、およびフーリエ係数の振幅を使用した場合(c3)、いずれもNNによる鑑別率の結果は100%である。しかし、それらのNNにおける出力層の値は、本実験ではTable 4.1のようにになっている。Table 4.1から最大値(*)と二番目に大きい値(**)との差がc1では、0.943、c2では、0.986、c3では、0.984であり、分離度の見地からみればc2、c3の方がc1より優れていることが容易に理解できる。一般に、NNを応用した市場の製品においては、出力ユニットの最大値のみならず最大値以外の出力値が最大値から十分離れていることが要求されている。なぜならば、市場においては外部の影響で入力データに雑音が混入した場合でもその出力結果が、正常なデータによる出力結果に可能な限り近いことが要請されているからである。つまり、出力ユニットの最大出力値とそれ以外の出力値が互いに近い状態の製品よりも、十分に離れた距離の出力を与える製品の方が望まれている。鑑別率 ES_1 のみで、このような評価を行うには不十分であり、この問題を考察するために以下では信頼性の評価規範を新たに導入する。

4.5.2 信頼性評価規範

ここでは、NNによる識別結果がどの程度の信頼性を有しているかを示す指標として信頼性評価規範を導入する。まず、ある入力に対し、パターン1からパターン12に対応した出力値がNNの出力ユニットから得られることに注目する。本章での識別判定は、この出力値の最大値を有するユニットのパターンを抽出する方法¹³⁾を採用している。しかしながら、この各出力ユニット値に着目すると、最大値とそれ以外の値との差を識別判定のための分離距離と見なすことが可能である。この分離距離を用いることによって、識別判定に対する信頼性を定量的に評価することができる。さらに、N個の同一金種に対する刺激を与えればそれに対応する出力ユニット値は、あるばらつきを有する確率分布に従うことになる。したがって、Fig.4.9に示すように、同一パターンの入力に対する出力ユニットの値の分布を求め、目的




Fig.4.9 Distribution of output values.

パターン(ユニット1)と排除パターン(ユニット2)との分布がクロスする上側確率を求める。この上側確率を信頼性評価規範と定義し、 ES_2 と記述する。ただし、ここで扱う出力ユニットの値のデータ分布は、 $[0, 1]$ 上で非対称な分布となるがその標準偏差が十分に小さいため正規分布 $N(\mu, \sigma^2)$ (μ :平均, σ :標準偏差)に従うものとする。したがって、信頼性評価規範 ES_2 は式(4.5)で与えられる。

$$ES_2 \triangleq \int_{\theta}^{\infty} \frac{1}{(2\pi)^{1/2} \sigma_p} \exp\left(-\frac{(x - \bar{x}_p)^2}{2\sigma_p^2}\right) dx \quad (4.5)$$

ただし、 σ_p :目的パターンのデータの標準偏差、 \bar{x}_p :目的パターンのデータの平均値、 x :目的パターンの出力ユニットの値、 θ :目的パターンのデータ分布と排除パターンのデータ分布との交点の x 座標を示す。

この信頼性評価規範 ES_2 を用いると ES_2 が小さいほど、識別の信頼性が高いと判断することができる。

4.5.3 信頼性の比較

Fig.4.10は、4.4.4節の鑑別率 ES_1 の比較に対して用いた3金種、4方向各10枚の場合に対する信頼性の比較を示している。比較アルゴリズムは、4.4.4節の鑑別

率 ES_1 の比較の場合と同様に、(1)高速処理機に採用されている識別式を用いた従来の識別手法、(2)時系列データを用いた NN による識別手法、(3)フーリエ係数 A 、 B を用いた NN による識別手法、および(4)フーリエ係数の振幅 $(A^2+B^2)^{1/2}$ を用いた NN による識別手法、(5)第 1 周波数から第 9 周波数までのフーリエ係数の振幅を用いた NN による識別手法とする。ここでは、3 金種、4 方向の 12 パターンに対し、 $12P_2=132$ 通りの誤識別の組合せがあり、それぞれに対して ES_1 を得ることができる。しかし、鑑別率と同様に結果の理解を容易にするために金種内の信頼性評価規範 ES_2 の最悪値を金種の代表値として選定し、その信頼性を検討する。Fig. 4.10 から分かるように、NN を用いた場合でも時系列データをそのまま NN の入力として使用するのでは、十分な信頼性が得られず、従来手法より低い性能となっている。これは、従来手法も時系列データをそのまま使用しているが、経験と試行錯誤により紙幣の搬送によるずれの影響を極力受けないポイントを識別点にしているためであると予想される。これに対し、フーリエ変換を施してから NN に入力する手法では、提示したどの手法においても、従来手法を大きく上回る性能を示している。




Fig. 4.10 Comparison of reliability.

つまり、紙幣の搬送によるずれの影響をフーリエ変換を施すことにより、縮小あるいは除去することが体系的にでき、安定した NN への入力が生成されているためであると思われる。また、4.4.4 節で述べたように鑑別率評価では、時系列データを用いた場合とフーリエ係数の振幅も含めたフーリエ係数を用いた場合では、NN による識別手法との間で性能差が認められない。しかるに、Fig. 4.10 からわかるように、信頼性評価規範 ES_2 に基づいた評価法では時系列データを用いた場合とフーリエ係数の振幅も含めたフーリエ係数を用いた場合の識別手法の間で性能差が明確に認められ、潜在的な識別性能を明確にすることができる。ただし、フーリエ係数とフーリエ係数の振幅を用いた場合の信頼性評価規範 ES_2 は 4 バイト長で計算しているため、本実験ではいずれも 10^{-65} 以下と表示されている。これについては、今後、8 バイト長の倍精度で計算することを検討している。

以上により、NN を用いたパターン認識システムの信頼性を評価するために、本章で提案した信頼性評価規範 ES_2 を導入することが妥当であることが示された。とくに、NN を用いた製品を市場に送り出す場合においては、鑑別率のみならず、信頼性の高い製品を送り出すことが必要であり、ここで導入した ES_1 および ES_2 の意義も大きくなるとと思われる。




Fig. 4.11 Histogram of output values.

つぎに、信頼性評価規範 ES_2 を算出する際の NN を用いた識別手法のヒストグラムを Fig. 4.11 に示す。ただし、Fig. 4.11 の「選択的フーリエ係数振幅 NN 」は、4.4.4 節または、4.5.3 節の「第 1 周波数から第 9 周波数までのフーリエ係数の振幅を用いた NN による識別手法」を示している。Fig. 4.11 のヒストグラムは、それぞれの手法の最も信頼性の低い場合を示し、手法毎に目的モードと排除モード間でスケールリングして表示している。このヒストグラムよりフーリエ係数の振幅も含めたフーリエ係数を用いた場合の NN の出力値が、時系列データを用いた場合の NN の出力値より安定していることが明確である。このことは、時系列データにフーリエ変換を施すことにより、 NN への入力をより安定したものとしていることを裏付けている。

4. 6 おわりに

本章では、搬送による雑音の影響が大きい高速処理機に対して、 NN を用いた識別手法の有効性を紙幣識別機による実データを用いたシミュレーションにより定量的に検証した。また、 NN による識別において、紙幣の時系列データをフーリエ変換し、このフーリエ係数の振幅も含めた、フーリエ係数の情報を入力した場合の方が時系列データを直接入力する場合より識別性能の点で優れていることを示した。さらに、得られるフーリエ係数の情報を全て使用しない選択的な使用においても従来の識別手法と同等以上の識別性能が得られることを定量的に検証した。このことは、本章で提案する NN を用いた識別手法を製品化する上で NN の規模の縮小と処理速度の向上に有効な情報になると思われる。また、 NN によるパターン認識の性能評価規範として従来から採用されていた鑑別率 ES_1 のほかに信頼性評価規範 ES_2 を導入した。この信頼性評価規範 ES_2 を導入することで、 NN の結果に対する信頼性を考察することができ、産業界での NN の応用をより一層促進できるものと思われる。しかしながら、 NN を用いた識別手法では、その識別アルゴリズムが学習により自己組織化されるため、誤識別が発生した場合には、第 2 章で示した識別式を設計者がトレースするように、誤識別のメカニズムをトレースすることが難しくなると予想される。そのため、製品化においてはこの事項を十分留意することが必要であり、この点は今後の検討課題となっている。

以上により、 NN は紙幣識別に対し性能および開発期間の点において優れた手法であることが確認できた。次章からは、これらの NN を用いた紙幣識別手法を実システムへ移植することに関して考察する。

第5章 ランダムマスクによるニューラル ネットワークの規模の縮小化と 紙幣識別への応用

5.1 はじめに

本章では第3章、4章の実験結果および考察を基にしてNNを用いた紙幣識別手法をいかに効率良くかつ容易に実システムへ移植するかについて検討を行う。

これまでに、NNによるパターン認識の研究は多数報告されている^{10)・18)}。また、産業界においてもこれらの研究の応用として手書き文字読み取り装置や音声認識装置などが試作され、従来のパターン認識アルゴリズムでは困難であった類似した入力情報に対してもNNは、有効であることが報告されている^{21)・22)}。一般に、パターン認識における問題解決にNNを導入することが有意義であることはよく知られている。適当な学習データと勾配法によるバックプロパゲーション法¹⁶⁾などの学習アルゴリズムにより、ある程度の認識性能を有するシステムを構築することが可能である¹⁴⁾。また、パターン認識の種類によっては、極めて類似した情報を分離することが必要な場合も存在するが、これにおいても、福島らのネオコグニトロン²³⁾のように、NNの隠れ層を多段にすることにより、入力情報の特徴をNNに抽出させることが可能である。しかしながら、これらはアルゴリズムの面からNNを用いたパターン認識における問題解決を論じたものであり、実用面ではこの限りではない。たとえば、NNを実装化する製品に対しては、採用するアルゴリズムのパターン認識能力に加えて製品のコンパクト性、処理速度、コストなどが重要な設計因子となる。通常、紙幣識別機の場合には、その市場における用途と識別機の仕様に応じてさまざまな機種が開発されている。たとえば、処理速度においても10枚/秒の処理能力を有する高速処理機から、1枚/秒の通常処理機までの機種が製品化されている。しかしながら、その識別アルゴリズムは、搬送速度と仕様に応じて随時、適材適所のものを開発しているのが現状である。つまり、設計者が搬送における紙幣の特徴パラメータを抽出し、このパラメータを用いて紙幣分離が可能か否かを大量の紙幣を用いて実験的に考察している。このように大量な紙幣から、紙幣の特徴パ

ラメータを探索し、そこで採用された特徴パラメータによる紙幣の分離可能性を検討する業務においては、試行錯誤の域を脱却できず多大な工数を必要としている。

本研究では、このような紙幣識別機に対してNNの応用可能性ならびにその識別性能をこれまでの章で検討してきた。しかしながら、製品に対するNNの実装化においては、NNの規模が大規模となり上述の製品のコンパクト性、処理速度さらにコストなどの面からNNを製品化することへの障害になっている。本章ではこれらの設計因子に直接関係するNNの規模の縮小化を図る手法を提案する。提案する紙幣識別に対する手法では入力画像の画素値の総和であるスラブ値^{11)・18)・24)・26)}を画像の特徴量として採用する。ただし、ここでは異なる画像に対して同一スラブ値が生成される可能性を避けるために、画像の一部をランダムに被覆するマスクを導入し、種々の視点から画像を観測してパターンの差異をスラブ値に反映させるランダムマスク方式^{24)・25)}を提案する。まず、ここで提案する手法を用いてNNの規模の縮小化を行うことができることを2値画像によって表現されたアルファベットを用いて定量的に検証する。ひきつづき、提案手法を濃淡画像である紙幣データに適用し、紙幣識別機への実装化に際してNNの規模の縮小化が可能であることを示す。

5.2 ランダムマスクによる画像特徴量算出の原理

5.2.1 画像特徴量としての画素値の総和

パターン認識において入力画像の特徴量をいかに抽出するかは重要な問題である。たとえば、濃淡画像に関する代表的な特徴量としては、平均、分散、エネルギー、エントロピー、フーリエパワースペクトルなどを列挙することができる⁶⁾。また、2値画像に対しては、図形の面積、重心、領域長、ホール数などの多種の特徴量が用いられている⁶⁾。ここでは、とくに画像のパターンを反映しつつ、ある程度計算が容易に行える特徴量として画素値の総和であるスラブ値^{11)・18)・24)・26)}に着目する。以下では、濃淡画像および2値画像のどちらに対しても計算が容易であるスラブ値を入力画像に対する特徴量として考察する。Fig. 5.1に示すように8×8のマトリックス上の0と1の2値画像において、画像の特徴量としてスラブ値を用いた場合、Fig. 5.1(a)では"E"を特徴づける値として14が得られ、Fig. 5.1(b)では"

H”を特徴づける値として12が得られる。したがって、スラブ値を用いることによって”E”と”H”が分離可能となる。しかしながら、異なるパターンを有する




Fig. 5.1 E, H patterns and slab values.




Fig. 5.2 F, K patterns and slab values.




Fig. 5.3 Mask and slab values.

画像でもスラブ値が等しくなる場合が存在する。たとえば、Fig. 5.2(a)では”F”のスラブ値は10であるが、Fig. 5.2(b)の”K”のスラブ値も10であり分離不可能となる。このような問題に対しては、Fig. 5.3(c)に示すような入力画像の画素に対応する特定の部分が被覆されたメッシュ状のマスクを導入することにより解決できる。Fig. 5.3(c)のマスクでFig. 5.2(a)の画像を覆うとFig. 5.3(a)に示す画像となり、この場合のスラブ値は7となる。一方、Fig. 5.3(c)のマスクでFig. 5.2(b)の画像を覆うとFig. 5.3(b)に示す画像となり、スラブ値は9となる。このようにマスクを導入することにより”F”と”K”も分離可能となる。以上のマスクとスラブ値の関係に対する考察に基づいて紙幣識別のための識別手法を以下で提案する。

5. 2. 2 提案手法の構成法と基本原理

5.2.1節で述べたスラブ値とマスクによるNNの新しい構成法と基本原理を述べる。また、スラブ値の計算は、濃淡画像と2値画像に対して同じように行うことができる。そこで、提案手法の原理の理解を容易にするために、前述した2値画像であるアルファベットに対して提案手法の説明を行う。

まず、種々の画像を分離するためにFig. 5.3(c)に示すようなマスクによって被覆される部分の位置を、ここでは、一様乱数を用いて無作為に選定する。この場合、ただ一つのマスクによって、種々の画像を分離できるスラブ値を生成する確率は極めて小さいと予想される。しかしながら、前述のように異なる種々のマスクを使用することによって同じ画像でも異なるスラブ値列を得ることができる。このスラブ値列のいずれかが画像間で異なることが多く、種々のマスクを利用することによって、画像間の分離能力を確率的に高めることが可能であると推測される。なお、上述の複数の異なるマスクを使用することはつぎのような物理的な意味を有している。つまり、3次元物体を多方向から視点を変えて観測する場合、同一の対象でも異なる情報を得ることができる。これと同様に、種々のマスクを用いることは2次元平面内で視点を変えて画像を観測することになり、前述のように同一の画像でも異なる情報を生成可能となる。

つぎに、マスクの被覆部分をFig. 5.4(a)またはFig. 5.4(b)のように列方向あるいは行方向に配列することにより、それぞれ、入力画像の上下方向の移動および左右




Fig. 5.4 Column and line masks.

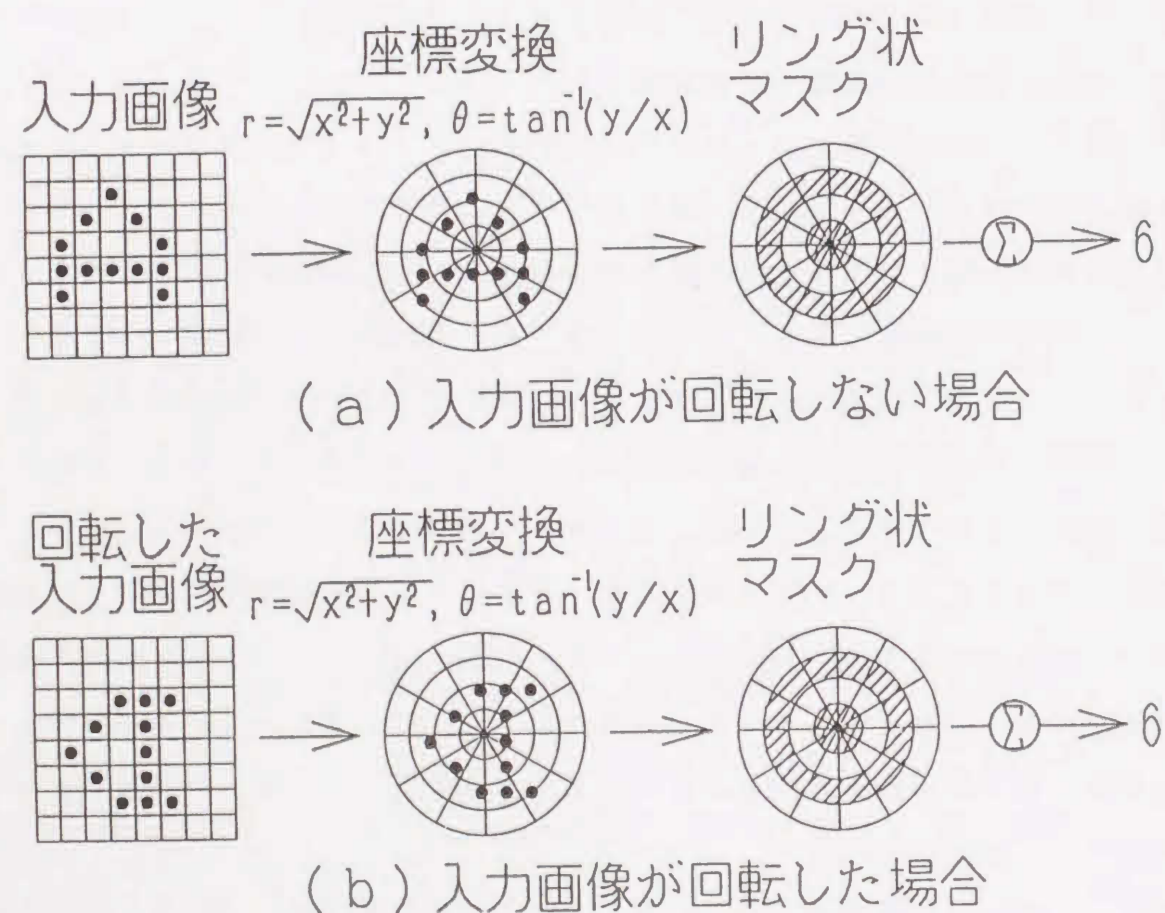


Fig. 5.5 Ring masks.

方向の移動に対して不変なスラブ値を得ることができる。さらに、上述のように 1 自由度に対して不変なスラブ値を生成するマスクを $x-y$ 直交座標系から $r-\theta$ 円筒座標系で取り扱うことにより回転に対して不変なスラブ値を得ることができる。Fig. 5.5 はこの考え方を模式的に示したものである。Fig. 5.5 から明かなようにリング状のマスクを用いた提案手法²⁷⁾によって、任意の画像の回転に対して不変なパターン認識システムを構築することが可能となる。以上の考察に基づいて提案手法の構成を Fig. 5.6 に示す。この Fig. 5.6 は前述の列方向、行方向、およびリング状のマスクを特別な場合として含むメッシュ状のランダムマスクを用いた提案手法を示している。この NN は 3 層構造であり、前処理で入力画像が種々の異なるマスクで覆われ、被覆されない画素の総和がスラブ値となり、入力層のユニットと一対一に対応している。また、出力層のユニット値は判定パターンに対応している。




Fig. 5.6 Construction of NN by proposed method.

ただし、提案手法におけるランダムマスクの考え方は、Rosenblattのパーセプトロン²⁸⁾において、SユニットとAユニットがランダムに結合されているということに類似している。しかし、パーセプトロンは網膜上の入力画像の2次元結合を工学で模倣する上で、各画素値にアナログ重みを乗算しており、その場合の重みをランダムに選択している。一方、提案手法では入力画像の各画素値に対して{0, 1}という2値の重みを乗算している。ここでは、異なる画像に対し、同一スラブ値が生成される可能性を小さくするためにこの重みをランダムに選択している。

また、アルゴリズム的にも、パーセプトロンは1層の学習しか行っていないため、線形分離しか可能ではないが、提案手法では2層の学習を行い、紙幣のような複雑なパターンでかつ揺らぎのある画像の識別を可能としている。これらの差異に加え、提案手法は、入力画像の固有情報の損失を少なくし、入力情報をコンパクト化することでNNの規模を縮小するという実用的見地に立脚し開発されたものである。

5. 2. 3 提案手法のWidrow的解釈

Widrowらは、パターン認識の基本構成要素としてシグナム関数を用いたモデルである線形適応ニューロン(ADALINE)を考案し、これを基にした位置ずれ、回転などの種々の変形に対して不変な多層ADALINEネットワークを提案した^{18), 26)}。このネットワークはFig. 5.7に示すようにインバリانسネットワークとディスクランブラネットワークから成り立っている。インバリانسネットワークは複数のスラブを有し、位置ずれ、回転などの種々の変形に対して不変な出力を生成する機能を有している^{18), 26)}。また、ディスクランブラネットワークは、ADALINEネットワークを学習させた後、オリジナルパターンを再生する機能を有している。Widrowらは、一つの入力画像に対して種々の拡散重み $W_i (i=1, 2, \dots, L)$ を使用し、入力画像が種々の変形を受けた場合でも不変であるような特徴要素をFig. 5.8に示すようなMAJ素子を用いて抽出している。このWidrowらの手法の独自性は、画像の変形情報をあらかじめ想定し、それを入力画像に与えることと、これらの情報を拡散重みを用いて確率的に扱っていることにある。著者らは、これらの特徴の内、MAJ素子にヒントを得てNNの規模の縮小化という観点から、ランダムマスクによるスラブ値を入力画像の特徴量として使用し、Widrow




Fig. 5.7 Construction of Widrow's algorithm.




Fig. 5.8 Slab and MAJ operator.

owらの手法と同様に一つの入力画像から複数のスラブ値を生成し、NNの入力としている。このことは、画像間においてパターンを特徴づけるスラブ値列のいずれかのスラブ値が確率的に異なり、NNによる画像の分離が可能となることを意味している。ただし、Widrowらの手法で回転不変なNNを構成する場合、そのスラブ値生成のための演算量は、拡散重みの回転操作により提案手法と比較してかなり多くなり、8ビットあるいは16ビットのCPUで認識処理を行う製品への実装化は難しくなると予想される。

5.3 アルファベットを用いた実験

提案手法のスラブ値生成部 (Fig. 5.6の一点鎖線内) ではマスク数と被覆領域がパラメータとして考えられる。本章では提案手法の適用対象を紙幣識別問題としているが、アルファベットは画像としての表現が簡単であり、提案手法に含まれるランダムマスクの効果を検証するのに適当であると思われる。したがって、ここでは 8×8 のマトリックス上に描かれたAからLの12個の2値画像を用いてパラメータ探索を行い、提案手法の認識能力を検討する。ただし、NNの学習アルゴリズムは、次式で与えられるバックプロパゲーション法^{16), 17), 20)}を用いる。

$$\Delta W(t) = -\varepsilon d_{i,j}^k + \alpha \Delta W(t-1) + \beta \Delta W(t-2) \quad (5.1)$$

ただし、 ΔW : 重みの修正量、 d : 一般化誤差、 o : 出力、 t : サンプル、 ε : 正の学習定数、 α : 慣性項の比例定数、 β : 振動項の比例定数、 i, j : ユニットの指定子、 k : 層の指定子を示す。

また、重みの修正は、各パターンの提示ごとに行う。各パターンごとに得られる出力層の値と教師値との差の2乗の総和が収束判定誤差以下になった場合または提示回数が最大提示回数に達した場合に学習を終了させる判定基準を設けている。ここで、提示回数とはAからLの全てのパターンに教師を提示した場合を1回として定義する。学習データはAからLまでをNNに逐次的に提示する。さらに、認識能力の評価規範として次式で与えられる鑑別率を用いる。

$$ES = \frac{\Delta}{\text{認識される入力画像の全個数}} \times 100 (\%) \quad (5.2)$$

5.3.1 提案手法によるマスク数の検討

ここでは、マスク数について学習状況と認識能力の点から検討を加える。まず、提案手法で使用するマスクをつぎのように作成する。つまり、入力画像の画素数と同じ64 ($= 8 \times 8$) の一様乱数を $[-1, 1]$ の区間で発生し、その中で負の乱数値に対応する番号の画素を被覆する。ここでは、乱数発生初期値を2, 4, 8, 16, 24, 32種類とする。初期値の違いが被覆位置の違いに対応するので、マスク数は、それぞれ、2, 4, 8, 16, 24, 32となる。これらのマスクを用いて、シミュレーションにてそれぞれの学習の収束性と認識能力を検討し、目的とする認識能力を有する最小のマスク数を選定する。

ただし、パターン分離に無効な画素が被覆されることを避けるために、まず、入力層に対し、全画素値を入力し、学習後、入力層と隠れ層における重みの中で0に近い重み (この場合0.01) に対応する入力ユニットの画素を被覆領域から除外した。




Fig. 5.9 Various mask numbers and learning status.

Fig. 5.9はこれらの6通りのマスク数に対する提示回数30,000回に至るまでのNNの学習状況を示している。ただし、Fig. 5.9は乱数の初期値を種々変化させた場合の平均（ここでは10回）を示している。横軸は教師データの提示回数、縦軸は2乗誤差を示している。また、学習データにはFig. 10(a)に示すようなノイズ（ノイズ位置の画素値を反転する）を加えたデータも含んでいる。Fig. 5.9より、マスク数が2の場合は明かに学習が収束せず、パターン分離が不可能である。マスク数が4の場合は、NNの学習がある程度収束傾向を示しているが、誤差曲線は振動的となっている。この場合、学習をさらに継続し、60,000回まで行ったが、2乗誤差は1.0以下にはならなかった。マスク数が8以上の場合は、Fig. 5.9より学習が収束することが示された。また、この場合の重みを用いてAからLまでを認識させ




Fig. 5.10 Additional noise for inputs.

た実験結果をFig. 5.11に示す。ただし、認識データには提案手法の汎化能力を確認するために、各パターンごとにFig. 5.10(b)に示すようなノイズを付加した画像についても考察する。ここでノイズとは2値画像に対し、ノイズ位置の画素値を反転

させることを意味している。Fig. 5.11からマスク数に関して、マスク数を増加させると汎化能力が向上する実験結果が得られている。しかしながら、マスク数の増加はNNの説明変数の増加であり、学習データに対するオーバーフィッティングの問題が生ずる。したがって、提案手法におけるマスク数の増加が必ずしも汎化能力の向上につながるとは言えないことに留意したい。

以上の実験から、マスク数は認識能力に大きく影響することが明かとなった。とくに、このアルファベットの認識においてマスク数の最適性を論議する場合、NNの規模の縮小化を図る意味でマスク数として8を選定する。したがって、以後ではマスク数を8として実験を行う。




Fig. 5.11 Various mask numbers and recognition ability.

5. 3. 2 提案手法によるマスク領域の検討

ここでは、マスクの被覆領域の大きさにより学習状況と認識能力を検討する。まず、被覆領域の変更は乱数の変動幅により行う。つまり、乱数の幅 $[-1, 1]$ を基準に




Fig. 5.12 Various mask areas and learning status.




Fig. 5.13 Various mask areas and recognition ability.

し、被覆領域の増加方向に、それぞれ、乱数の幅を $[-2, 1]$, $[-3, 1]$, $[-4, 1]$ とし、被覆領域の減少方向に乱数の幅を $[-1, 2]$, $[-1, 3]$, $[-1, 4]$ として乱数を発生させる。ただし、マスク数は8とする。Fig. 5.12は乱数の幅を変化させた場合、提示回数が30,000回に至るまでの学習状況を示している。ただし、Fig. 5.9と同様に、Fig. 5.12は乱数の初期値を種々変化させた場合の平均（ここでは10回）を示している。横軸および縦軸はFig. 5.9と同様である。また、学習データにはFig. 5.9と同様にノイズを加えたデータも含んでいる。Fig. 5.12から学習は、マスクの被覆領域が少ないと振動的になる結果が得られている。これは、異なる入力画像でも被覆領域が少ないために固有スラブ値が生成されにくくなっているためであると予想される。しかしながら、学習は収束傾向を示している。また、Fig. 5.13はFig. 5.11と同様に、この場合の重みを用いてAからLまでを認識させた実験結果である。この実験では、汎化能力はマスクの被覆領域にあまり依存しない結果が得られた。

5. 3. 3 従来手法との比較

本章では、提案手法による認識能力を考察するために、第3章ですでに提案した入力画像を直接NNの入力層に入力する文献(7)の手法と比較検討する。文献(7)の手法の構成は提案手法と同様に3層構造である。しかしながら、入力層のユニット数は入力画素数と同じ64 ($= 8 \times 8$)である。また、隠れ層のユニット数は32であり、出力層のユニット数は判定パターンと同じ12とする。ただし、文献(7)の手法では隠れ層のユニット数をその認識能力とユニット数を考慮して種々の実験により決定した。提案手法と文献(7)の手法において2乗誤差が0.01になるまで学習させたときの提示回数は、前者が61,983回であり、後者が978回であった。ただし、前者に対しては $\varepsilon = 0.01$, $\alpha = 0.9$, $\beta = -0.1$ として、後者に対しては $\varepsilon = 0.1$, $\alpha = 0.9$, $\beta = -0.1$ として学習を行った。ただし、 ε は学習ステップ幅、 α は慣性項の比例定数、 β は振動項の比例定数である。また、両手法により上述の重みを用いて学習に用いたデータを再度認識させた場合、その鑑別率はいずれも100%であった。また、NNの規模を重みの個数で表現すると、提案手法の重みの個数は $8 \times 8 + 8 \times 12 = 160$ であり、一方、文献(7)の手法の重みの個数は $64 \times 32 + 32 \times 12 = 2,432$ であった。これらのことにより、提案手法は収束に時間を要するが、認識能力を

損うことなくNNの規模を縮小できることが明かとなった。

5. 4 紙幣データを用いた実験

この節では、現在製品化されている紙幣識別機から採取されたデータに提案手法を適用し、紙幣識別機におけるネットワークの規模の縮小化の可能性とその識別性能について検討する。ただし、学習アルゴリズム、2乗誤差、収束判定および鑑別率は5. 3節で与えたものとする。

5. 4. 1 提案手法による実験

5.3節では2値画像を用いて提案手法の有効性を定量的に検証した。ここでは0から255の濃淡画像である紙幣データを用いて、提案手法の有効性を検証する。ただし、ここで扱う紙幣データはFig. 5.14に示すようなセンサレイアウトから採取される時系列データであり、経験的に紙幣の特徴を代表するものとなっている。図中の点線の方形は個々のセンサが紙幣の搬送によりセンシングする領域を示している⁷⁾。実験は以下の二つの場合について行う。一つは紙幣時系列データ（以後時系列データと略記する）を提案手法に入力する場合であり、もう一つは時系列データをセンサごとに次式でフーリエ変換し、そのパワースペクトル（以後フーリエパワースペクトルと略記する）を提案手法に入力する場合である。

$$A(n) = 1/N \sum_{k=1}^N f(k) \cos\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=0, 1, 2, \dots, N/2-1, N/2)$$

$$B(n) = 1/N \sum_{k=1}^N f(k) \sin\left(\frac{2\pi}{N} (k-1)n\right) \quad (n=1, 2, \dots, N/2-2, N/2-1) \quad (5.3)$$

ただし、 $f(k)$ ：紙幣データ、 N ：データ数、 $A(n)$ 、 $B(n)$ ：フーリエ係数を示す。なお、 $f(k)$ のフーリエ変換を $F(n)$ 、すなわち、 $F(n)=A(n)+jB(n)$ とする。ここで、時系列データのフーリエパワースペクトルを採用するのはつぎの理由に基づいている。つまり、ここで取り扱う紙幣識別機において紙幣は8枚/秒以上で識別され、

その搬送速度は600mm/秒以上である⁷⁾。この識別機により採取されるデータは、紙幣の搬送による種々の誤差を含んだものとなっており、とくにサンプルずれによる誤差の比重は大きいと予想される。したがって、時系列データのフーリエパワースペクトルを用いればこの誤差を除去することができ、識別能力の向上につながると予想されるからである⁷⁾。提案手法の構成は、時系列データを用いる場合とそのフーリエパワースペクトルを用いる場合のいずれに対してもマスク数を16とする。したがって、NNの入力層のユニット数は16となり、また隠れ層のユニット数は




Fig. 5.14 Bill money data and sampling method.

入力層と同じ16とする。出力層のユニット値は判定パターンに対応し、その個数は12である。これは、識別の対象を偽造紙幣を含まない真の紙幣とし、1万円、5千円、千円の3金種の各々に対して、表正立、表倒立、裏倒立、裏正立の4搬送方向へ分類することを意味している。なお、時系列データおよびフーリエパワースペクトルを用いた場合のマスク数は5.3.1節と同様に種々の実験により学習の収束性とユニット数を考慮して決定されている。これらの条件下で紙幣識別を行った結果をFig. 5.15に示す。ただし、図中でFFTデータはフーリエパワースペクトルを意味している。Fig. 5.15から明かなように、時系列データおよびそのフーリエパワースペクトルを提案手法へ適用した場合、どちらのデータにおいても学習を2乗誤差




Fig. 5.15 Experiment with bill money data.

が0.01になるまで収束させることができた。ここで、Fig. 5.15の横軸および縦軸はFig. 5.9と同様に教師の提示回数と2乗誤差を、それぞれ、示している。また、これらの重みを用いて学習データとは別の3金種4搬送方向の合計12パターンの紙幣データ各10枚を識別した場合、鑑別率はいずれも100%であった。

5.4.2 従来手法との比較

5.3.3節と同様に、提案手法の比較手法として時系列データおよびそのフーリエパワースペクトルを直接NNの入力層に入力する手法を採用する。この比較に用いる第4章で述べた文献(7)の手法に時系列データを入力する場合、そのNNの入力層のユニット数は画素数と同じ128(=32サンプル×4センサ)である。また、隠れ層のユニット数は64とし、出力層のユニット値は5.4.1節と同様に判定パターンに対応し、その個数は12である。時系列データのフーリエパワースペクトルを文献(7)の手法に入力する場合、そのNNの入力層のユニット数は68(=17×4センサ)であり、隠れ層のユニット数は64、出力層のユニット数は上述のよ

うに12である。ただし、これらのデータに対する文献(7)の手法の隠れ層のユニット数は、5.3.3節と同様に種々の実験により、識別能力とユニット数を考慮して設定した。時系列データおよびそのフーリエパワースペクトルを文献(7)の手法に用いた場合、2乗誤差が0.01に減少するまでの学習状況をFig. 5.15に示す。この図より時系列データおよびそのフーリエパワースペクトルのどちらのデータを用いた場合に対しても提案手法の方が文献(7)の手法と比較して目標誤差に至るまでの提示回数が、多くなっている。このことは、5.3.3節のアルファベットを用いた実験に対しても同様であり、提案手法の問題点であると思われる。しかしながら、紙幣識別においては通常、制御におけるNNのように学習に対するリアルタイム性は要求されていない。それゆえ、提案手法は2乗誤差が収束傾向を有しているのであれば、学習に十分な時間を費やすことにより2乗誤差を任意の数値に収束させることが可能であると予想される。したがって、上述のような問題点は紙幣識別に関する限りあまり重大ではない。また、これらの重みを用いて5.4.1節と同様に学習データとは別の3金種4搬送方向の合計12パターンの紙幣データ各10枚を識別した場合でも鑑別率は100%であった。さらに、5.3.3節と同様にNNの規模を重みの個数で評価すると、提案手法および文献(7)の手法の重みの個数は時系列データを用いた場合およびそのフーリエパワースペクトルを用いた場合について、それぞれ、以下のようであった。

時系列データ：

$$\text{提案手法} = 16 \times 16 + 16 \times 12 = 448$$

$$\text{文献(7)の手法} = 128 \times 64 + 64 \times 12 = 8,960$$

フーリエパワースペクトル：

$$\text{提案手法} = 16 \times 16 + 16 \times 12 = 448$$

$$\text{文献(7)の手法} = 68 \times 64 + 64 \times 12 = 5,120$$

これらのことにより、提案手法が濃淡画像である紙幣データに対しても有効であり、かつ識別能力をも損なわないことが明かとなった。

また、これとは別に文献(7)の手法で入力層と隠れ層の重みを調査して0に近い重みに対する隠れ層のユニットを除去してNNを縮小する方法が考えられる。しかしながら、これにおいては紙幣データに関する限り、学習データの提示方法ならびに学習定数の細かい調整を必要とし、あまり体系的なNNの規模の縮小化手法で

はないと思われる。

5. 5 提案手法を用いた他の応用例

5.2.2節のFig.5.5でリングマスクを採用した提案手法の基本原理を示し、その回転不変性を述べた。ここでは、提案手法の具体的な応用例として回転不変性を必要とする硬貨識別を検討し、シミュレーションによる実験結果を示す。識別の対象とするパターンはFig.5.16に示すような500円の表、裏と500円にその形状および図柄が類似した韓国の500ウォンの表、裏の合計4パターンとする。硬貨の画像は40×40画素で1バイトのグレイレベルを有している。NNの構成は3層構造であり、




Fig.5.16 Coin's data.

それぞれのユニット数を20, 20, 4とする。Table 5.1に任意に回転した未学習の硬貨データを各パターン50枚識別した実験結果を示す。ただし、学習データにも任意に回転した硬貨データを使用している。Table 5.1より、提案手法が回転に対して有効であることが明確に示されている。

Table 5.1 Recognition result for coin.

		各パターン毎の学習データ数				
		1枚	2枚	3枚	4枚	5枚
鑑別率 (%)	500円 表	100	98	100	100	100
	500円 裏	80	100	98	100	100
	500ウォン 表	56	92	92	98	100
	500ウォン 裏	60	82	92	100	100

5. 6 おわりに

本章では、NNの規模の縮小化を体系的に図る手法を提案し、2値画像であるアルファベットによりその基本原理を述べた。さらに、濃淡画像である紙幣データに対して有効であることをシミュレーション実験によって定量的に検証した。とくに、画像のパターンをその特徴量としてスラブ値に反映させるため、画像を異なる視点で観測する必要性からランダムマスクを新たに導入し、画像の固有のスラブ値が確率的に求められることを示した。さらに、このマスクを工夫することにより1自由度の位置ずれ、あるいは回転に対して不変なNNを構成することが可能であることもアルファベットを用いてその原理を示した。また、リングマスクによる提案手法の実験結果についても検討した。ただし、ここで提案する手法は原理的に画像情報を平均化処理しているため、NNの収束を抑制することになる。しかしながら、学習が収束傾向を示している限り、学習に十分な時間を費やすことによって、目標とする収束誤差にまでNNを学習させることができ、紙幣識別に十分応用することが可能と思われる。とくに、NNによる紙幣識別機の開発において提案手法は、識別

機のコンパクト化，処理速度の高速化，低コスト化をアルゴリズム面から促進するものと思われる。

次の第6章では，実際に実験システムを構築し，NNの学習による自己組織化を利用した多国紙幣混合識別に関する実験を行い，その結果について考察する。

第6章 ランダムマスク方式による ニューロ紙幣識別機の開発

6.1 はじめに

本章では，第3章から5章までの実験と考察に基づき，NNによる紙幣識別用実験システムの構築を行い，その性能と製品化への可能性を検討する。

ここで用いる紙幣識別機はすでに日本紙幣を対象として製品化されており，その識別手法は第1章で述べたような識別関数に属するものが使用されている。本章では，この識別機とランダムマスク方式によるNNの学習および識別ソフトウェアが移植されたパーソナルコンピュータを用い，日本の千円，五千円，一万円，および，韓国の千ウォン，五千ウォン，一万ウォン，さらに米国の1ドル，5ドル，20ドル，50ドルの合計10種類の金種の識別を実現するものである。

この実験システムにおける識別機は紙幣の搬送系およびセンサ系としての位置づけとなる。本研究では，実験システムにより種々の紙幣サイズ，さらには種々の色相の紙幣が混入した場合の金種識別が，入力層16ユニット，隠れ層16ユニット，出力層10ユニットの小規模なネットワーク構成によって実現可能であることを実験により確認する。これにより，提案するランダムマスク方式によるNNの識別手法が性能および製品化において有効であることを示す。

6.2 ランダムマスク方式によるニューロ紙幣識別の原理

本章では，画像のパターンを反映しつつ現在製品化されている紙幣識別機が有する8ビットあるいは16ビットのCPUで計算が簡易に行える特徴量として，第5章で述べた画素値の総和であるスラブ値^{(24)-(27), (30)}に注目する。以下では，このスラブ値を入力画像に対する特徴量として考察する。ここでは，ランダムマスク方式によるニューロ識別の原理の理解を容易にするためにFig. 6.1に示すように，紙幣画像を 16×8 のマトリックス上の{0, 1}の2値画像として模式的に示す。

まず，画像の特徴量としてスラブ値を用いた場合，Fig. 6.1(a)では”\$1”を特徴づ

ける値として31が得られ、Fig.1(b)では"¥1000"を特徴づける値として25が得られる。したがって、"\$1"と"¥1000"は識別可能となる。しかしながら、Fig.6.2のように異なる画像でもスラブ値が等しくなる場合が存在する。例えば、Fig.6.2(a)では"¥5000"のスラブ値は23であるが、Fig.6.2(b)の"W1000"のスラブ値も23であり、識別不可能となる。このような問題に対しては、Fig.6.3(c)に示




Fig.6.1 Different patterns and different slab values.




Fig.6.2 Different patterns and same slab values.

すような入力画像の特定の部分を被覆するマスクを導入することにより解決できる。つまり、Fig.6.3(c)のマスクでFig.6.2(a)の画像を覆うとFig.6.3(a)に示す画像となり、この場合のスラブ値は13となる。一方、Fig.6.3(c)のマスクでFig.6.2(b)の画像を覆うとFig.6.3(b)に示す画像となり、スラブ値は23となる。したがって、マスクを導入することにより画像の違いをスラブ値に反映させることができ、識別が可能となる。ただし、この場合ただ一つのマスクによって種々の画像の違いをスラブ値に反映させるマ

スクを生成できる確率は極めて小さいと予想される。そこで、被覆領域が異なる複数のマスクを用いることにより、いずれかのマスク処理によるスラブ値が画像間で異なる確率が高くなると予想でき、多層NNのような非線形分離問題を得意とするアルゴリズムへの都合の良い入力となり得ると思われる。




Fig.6.3 Mask and slab values.

6.3 実験システムの構築

以下では、実際の紙幣識別機と提案アルゴリズムを用いた実験システムの構築を述べる。ここで用いる紙幣識別機は、すでに製品化されており、 216×30 画素で1バイトの濃淡レベルを有する画像データを採取することができる。また、紙幣の搬送速度は10枚/秒である。また、紙幣投入口は日本の1万円札よりやや大きめに設定しており、紙幣は短手方向（紙幣の短辺方向と平行）に搬送される。識別する紙幣は日本の千円、5千円、1万円および韓国の千ウォン、5千ウォン、1万ウォン、さらに米国の1ドル、5ドル、20ドル、50ドルの合計10金種の表正立方向⁷⁾とする。

6.3.1 システム構成の概要

実験システムのNNの構成をFig. 6.4に示す。前述のように紙幣投入口が最大紙幣である1万円札よりさらに大きいので、1万円より小さいサイズの紙幣が、搬送方向垂直に移動する可能性が存在する。したがって、ここでは第5章で提案したアルゴリズムの中の紙幣の搬送方向に垂直な位置ずれに対し、ロバストな行方向マスク方式を採用する。また、第5章で提案したアルゴリズムのマスクの種類とその被覆領域の検討と同様に、種々のシミュレーション実験により、マスクの種類を16とする。したがって、入力層のユニット数は16となる。ただし、一つのマスクにおける被覆領域は、画像全体の30ラインの内4ラインを任意に被覆する。ここで、1ラインとは紙幣の長辺方向にセンシングされた216個の画素の並びを示す。また、隠れ層のユニット数を16とし、出力層のユニット数は10とする。とくに、出力層の各ユニットは、それぞれ、千円、5千円、1万円および千ウォン、5千ウォン、1万ウォン、さらに1ドル、5ドル、20ドル、50ドルに対応させる。

Fig. 6.5に実験システムの模式図を示す。また、Fig. 6.6に実験システムの写真を示す。これらの図に示すように、紙幣識別機とパーソナルコンピュータは、パラレルケーブル




Fig. 6.4 NN construction of experimental system.

とシリアルケーブルにて接続されている。パラレルケーブルを通して、紙幣データがパーソナルコンピュータのRAM上に転送される。また、シリアルケーブルを通して、紙

幣データ読み取り終了信号がパーソナルコンピュータに転送され、ニューロ学習もしくはニューロ識別が開始される。パーソナルコンピュータ上には、C言語にて記述された提案アルゴリズムによる学習および識別プログラムが移植されている。




Fig. 6.5 Features of experimental system.




Fig. 6.6 Photograph of experimental system.

6.3.2 ハードウェア構成

Fig. 6.7に識別機のセンサ系からパーソナルコンピュータまでのデータ通信ボードを含むハードウェア構成を示す。識別機のセンサから得られたデータは内部のバスラインから分岐し、データ通信ボードを経てパーソナルコンピュータに入力される。コンピュータは画像データを1ページ（紙幣1枚分）毎に切り分けてニューロ識別処理を行う。

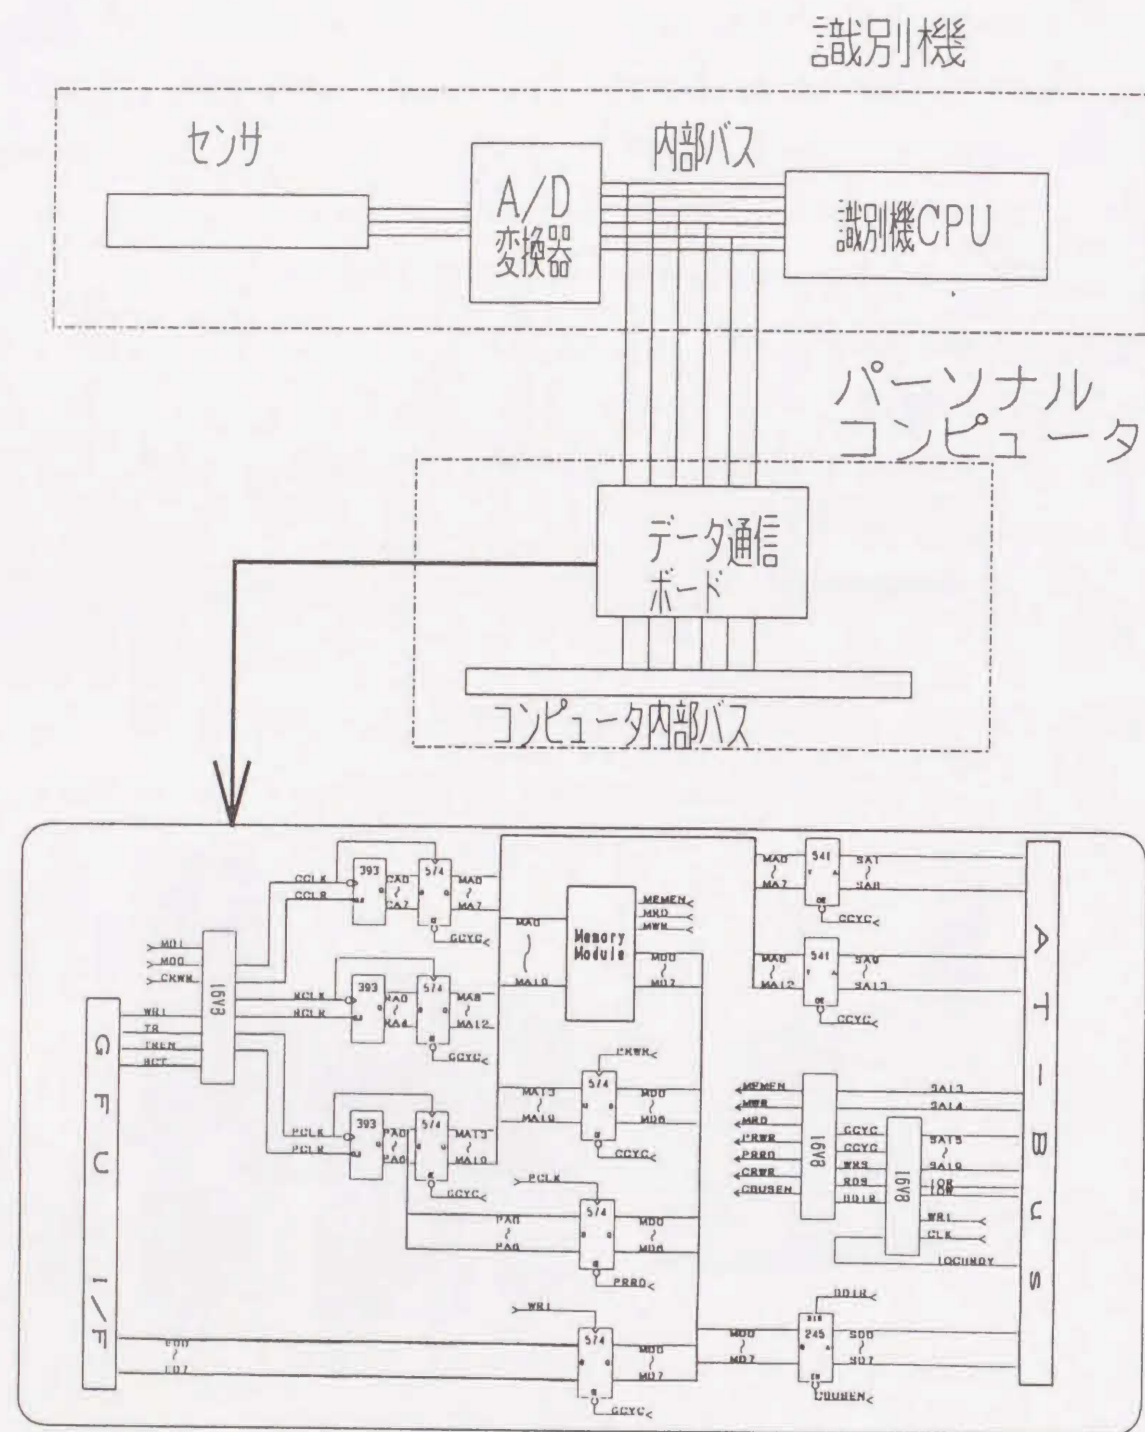


Fig. 6.7 Hardware configuration of experimental system.

6. 3. 3 ソフトウェア構成

Fig. 6.8にパーソナルコンピュータに移植されたランダムマスク方式によるニューロ識別ソフトウェアの処理フローを示す。

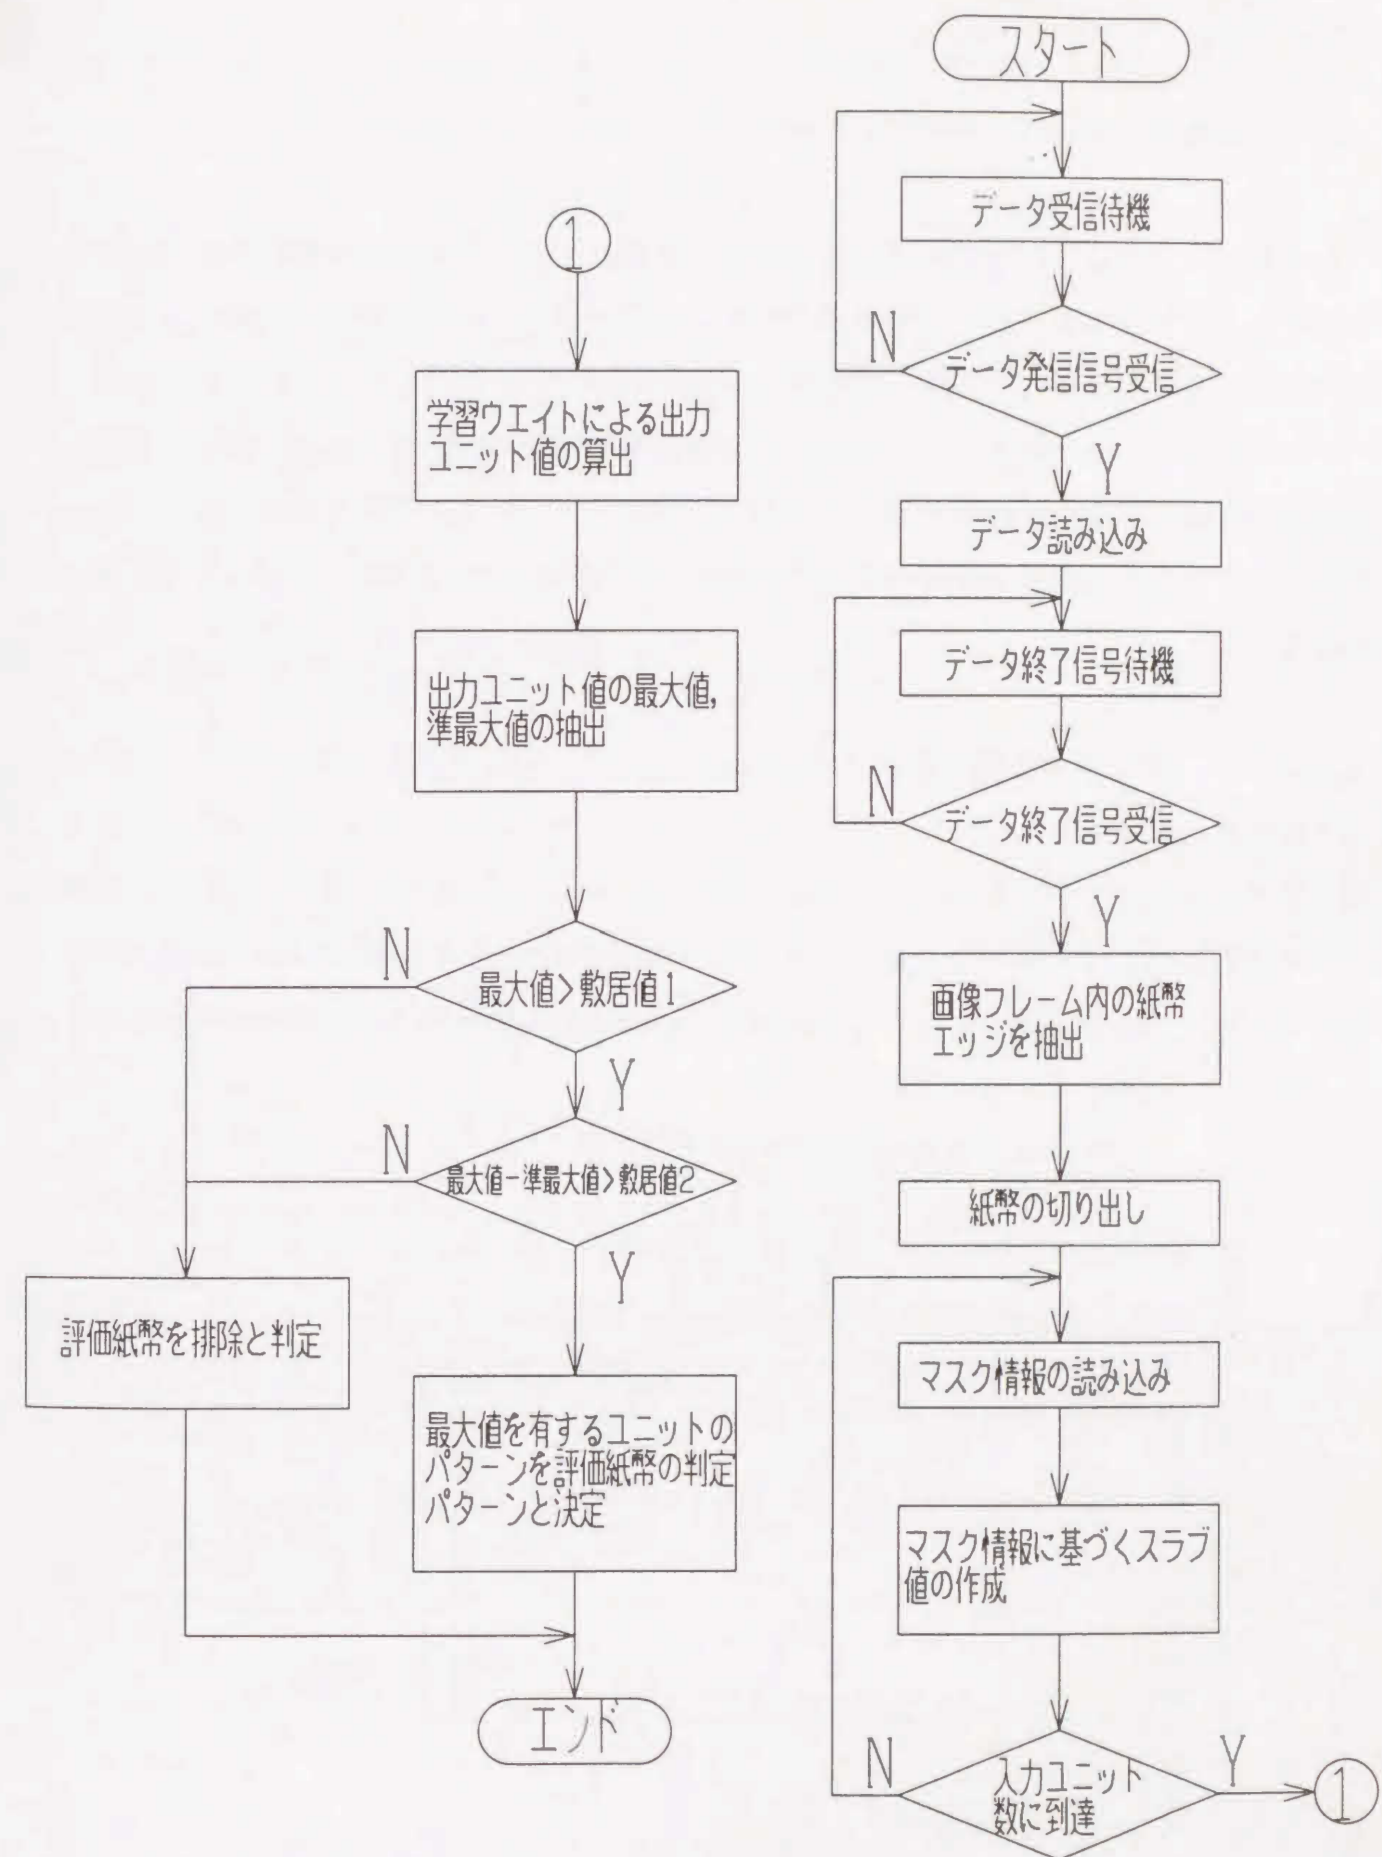


Fig. 6.8 Software configuration of experimental system for recognition.

6.4 紙幣データによる実験

この節では、前述した実験システムと極端に疲弊していない種々の真の紙幣を用いてオンラインで識別実験を行い、その識別性能と紙幣の搬送におけるデータの揺らぎに対する汎化性を考察する。

とくに、ここで扱う紙幣の内、日本および韓国は金種間でサイズと色相が異なる特徴を有している。一方、米国紙幣は各金種間でサイズは同一であり、色相も緑色系で同一である。ただし、今回の識別の対象とする裏面（風景画像）は金種間で多少の差異が認められる。

6.4.1 学習法と識別データ

ここでは、第5章と同様のバックプロパゲーション法を用い、Fig. 6.9に示すようなサイズの異なる紙幣10金種の分類のための学習を行う。ただし、紙幣の搬送による種々のデータばらつきを学習に反映させるために、各金種ごとに20枚分の紙幣データを学




Fig. 6.9 Various size of bill money.

習データとする。学習は32ビットコンピュータに浮動小数点演算プロセッサを付加して提示回数が50,000回に至るまで行った。この場合の2乗誤差の総和は0.005であった。

6.4.2 識別結果

提案アルゴリズムによる識別実験は、前述の2乗誤差の総和が、0.005になった場合の重みを用いて行う。この場合の紙幣の搬送速度は、学習のための紙幣データを採用した場合と同様に、10枚/秒とする。実験では、おのこの金種に対し、市場流通紙幣10枚を10回識別評価し、次式で与えられる鑑別率の平均値を識別能力とみなす。

$$\text{鑑別率} = \frac{\Delta \text{正しく識別された紙幣の枚数}}{\text{全紙幣の評価枚数}} \times 100 \quad (6.1)$$

Table 6.1に実験結果を示す。この表から、5千円の平均鑑別率が最も低く、90%である。これに対しては、学習において5千円に対する出力ユニットにおける2乗誤差が、他のユニットにおける2乗誤差と比較して大きいことに起因している。つまり、5千円に対しては、他の金種ほど学習が進んでおらず、それだけデータのばらつきに対するNNの汎化能力も小さいと予想される。

Table 6.1 Recognition ability of experimental system.

	円(¥)			ウォン(W)			米ドル(\$)			
金種	1,000	5,000	10,000	1,000	5,000	10,000	1	5	20	50
平均鑑別率	95%	90%	97%	100%	97%	95%	95%	95%	100%	100%

とくに、製品化に対しては、識別能力である平均鑑別率を全ての金種に対し、限りなく100%に近付けることが必要である。これにおいては、いかにNNの汎化能力を大きくするかが重要な課題となる。それには、データばらつきの解析とそれに対応する学習データの選定がまず考えられる。とくに、今回の学習において、紙幣の搬送路における回転（最大約 $\pm 8^\circ$ 程度）を意識的に学習データに反映させなかったことが、十分な識別能力を得られなかった原因の一つであると予想される。これにおいては、学習データの選定と共に、現在検討中である。

6.5 おわりに

本章では、本研究のまとめとしてNNの規模の縮小化を体系的に図るアルゴリズムを提案し、実際に実験システムを構築し、提案手法の有効性を示した。とくに、提案手法において画像のパターンをその特徴量としてスラブ値に反映させるため、画像を異なる視点で観測する必要性からランダムマスクを新たに導入し、これにより画像の固有のスラブ値を得る確率が高くなることを示した。さらに、ここで構築した紙幣識別機と32ビットコンピュータによる実験システムにより、外国紙幣が混合した場合の紙幣識別が実現可能であることを具体的に実証した。

今後、NNによる紙幣識別機の開発において提案アルゴリズムは、識別機のコンパクト化、処理速度の高速化、低コスト化の観点から、重要視されるものと思われる。しかしながら、マスクの生成法に関して、本件では乱数を用いその任意性により画像情報をスラブ値に反映させたが、学習の効率化と汎化能力の向上から効率の良いマスクの生成法が必要となる。このマスクの最適化を図ることに對し、遺伝アルゴリズムの導入が有効と考えられ、今後の検討課題としている。

第7章 おわりに

貨幣を基礎とした経済社会の下で、急速な高度情報化社会の進展とその技術を利用したOA化の進展が著しく、最新のコンピュータ技術を活用した貨幣識別技術の開発が現代社会ではとくに重要な問題となっている。本研究では、貨幣識別技術の知的情報処理のアプローチとして、エキスパートシステムとニューラルネットワークの二つの手法を導入し、貨幣識別機の識別精度の向上とインテリジェント化を図る研究を行った。前者は、従来の紙幣識別手法における分離関数式決定にエキスパートシステムを応用した技術であり、後者は、ニューラルネットワークそのものによる紙幣識別技術である。

とくにニューラルネットワークにおいて、本研究ではフーリエ変換などを利用した入力情報の選定法に対する検討を行い、さらに識別結果に対する信頼性に対しては、新しい評価規範の導入を行い、その詳細な検討を行った。

また、このような識別性能および開発期間の点において非常に優れたニューラルネットワークを実際の識別機へ低コストでかつコンパクトに実装化するための手法として、新たにランダムマスク方式を提案した。この手法により、識別性能の劣化を最小限にとどめ、大幅なネットワークの規模の縮小化ができることをシミュレーション実験により定量的に示した。さらに、本手法を用いて既存の識別機とパーソナルコンピュータによる実験システムを構築し、単一国の紙幣のみならず多国の紙幣が混合した場合の金種識別が可能であることを実験により示した。

また、本研究での提案手法および実験結果とその考察は貨幣識別機だけでなく他の産業界におけるニューラルネットワークの製品化をアルゴリズム面からよりいっそう促進することができると期待される。

以上のような研究を通じて、貨幣識別機のインテリジェント化を進めてきだが、とくに、エキスパートシステムの導入においては、設計者のノウハウおよび経験的な知識を用い、開発工数の短縮および識別精度の向上を図ることが可能となった。また、ニューラルネットワークの導入においては、貨幣識別手法に柔軟性およびロバスト性を付与することができ、人間の判断により近い“柔らかな機械”が実現できる可能性を示すことができた。さらに、ソフトウェアの開発のみならず、そこで

示された識別精度を高速に実現するために必要なハードウェアの開発も行い、理論的な側面のみならず実装化の側面からも研究を行ってきた。これらの研究は、次世代の"Real World Computer"が具備すべき内容に沿ったものであり、高度情報化社会の基礎技術となって、今後大いに利用されるものと確信している。

参考文献

- [1] 大須賀：知識ベース入門，オーム社（1986）
- [2] 田中：知識工学，朝倉書店（1989）
- [3] 増位：エキスパートシステム技術の応用に関する新しい動向，電気学会論文誌 C分冊，Vol.110，No.9，pp.450-454（1990）
- [4] ICOT-JIPDEC AIセンター：知的情報処理システムに関する調査研究報告書（全5分冊），63-A001～63-A005（1989）
- [5] 奥野，久米，吉澤，芳賀：多変量解析法，日科技連，pp.259-319（1984）
- [6] 長尾：パターン情報処理，電子情報通信学会，コロナ社（1986）
- [7] 竹田，大松，井上，尾波：ニューラルネットワークを用いた高速搬送紙幣の識別，電気学会論文誌 C分冊，Vol.112，No.4，pp.249-258（1992）
- [8] 志村，安岡，鈴木：確率と統計演習，共立出版（1979）
- [9] 麻生：ニューラルネットワーク情報処理，産業図書，pp.69-93（1989）
- [10] 竹田，大松，井上，尾波：フーリエ変換を前処理とするニューラルネットワークによる紙幣識別，システム制御情報学会論文誌，Vol.5，No.7，pp.265-273（1992）
- [11] M.Fukumi, S.Omatu, F.Takeda, and T.Kosaka, "Rotation Invariant Neural Pattern Recognition System with Application to Coin Recognition," IEEE Trans. on Neural Networks, Vol.3, No.2, pp.272-279（1992）
- [12] 林，駒沢：情報処理と統計数理，産業図書，pp.307-361（1975）
- [13] 勘解由，大西，杉江：回転と大きさに対して不変な文字認識，信学技法，NC 90-58，pp.31-37（1991）
- [14] 松本，大津：ニューロコンピューティングの周辺，培風館，pp.8-81（1991）
- [15] 添田，中溝，大松：信号処理の基礎と応用，日新出版，pp.27-61（1986）
- [16] 麻生：バックプロパゲーション，コンピュータロール，pp.53-60（1988）
- [17] 浅川：ニューロコンピュータによるロボットの学習制御，コンピュータロール，pp.108-115（1988）
- [18] 竹田，大松：マスク方式によるニューロ紙幣識別機の開発，システム制御情報学会論文誌，Vol.6，No.6，pp.283-289（1993）

- [19] 竹田, 大松, 井上: 紙幣識別の識別式決定に対するエキスパートシステム, 情報処理学会論文誌, Vol.33, No.7, pp.980-991 (1992)
- [20] S.Nagata, M.Sekiguchi, and K.Asakawa, "Mobile Robot Control by a Structured Hierarchical Neural Network," IEEE Control System Magazine, Vol.10, No.2, pp.69-76 (1990)
- [21] 甘利: ニューロコンピュータの現状と将来, 共立出版 (1990)
- [22] F.Takeda and S.Omatu, "Bill Money Recognition Using a Small Size Neural Network," Progress in Neural Network (1994) (will be appeared)
- [23] 福島: 神経回路と自己組織化, 共立出版 (1979)
- [24] F.Takeda and S.Omatu, "Bank Note Recognition System Using Neural Network with Random Masks," Proceedings of the World Congress on Neural Networks, Portland, USA, Vol.1, pp.241-244, (1993)
- [25] F.Takeda, S.Omatu, T.Inoue, and S.Onami, "A Structure Reduction of Neural Network with Random Masks and Bill Money Recognition," Proceedings of the 2nd International Conference on Fuzzy Logic and Neural Networks, Vol.2, pp.809-813 (1992)
- [26] B.Widrow, R.G.Winter, and R.A.Baxter, "Layered Neural Nets for Pattern Recognition," IEEE Trans. Acoust., Speech & Signal Process., Vol.36, No.7, pp.1109-1118 (1988)
- [27] 松下, 竹田, 大松, 福見, 小坂: 小規模ネットワークによる回転に不変な画像認識, システム制御情報研究発表講演会講演論文集, pp.553-554 (1992)
- [28] Marvin L. Minsky, and Seymour A. Papert: Perceptrons, MIT PRESS, pp.1-20 (1972)
- [29] 五味, 川人: フィードバック誤差学習による閉ループシステムの学習制御, システム制御情報学会誌, Vol.4, No.1, pp.37-47 (1991)
- [30] F.Takeda, S.Omatu, T.Inoue, and S.Onami, "High Speed Conveyed Bill Money Recognition with Neural Network," Proceedings of the IMACS/SCINE International Symposium on Robotics, Mechatronics and Manufacturing Systems '92 Kobe, Japan, Vol.1, pp.16-20 (1992)

関連発表論文

- [1] 竹田, 大松, 井上, 尾波: フーリエ変換を前処理機構に有するニューラルネットワークによる紙幣識別, 電気関係学会四国支部連合大会講演論文集, pp.467-468 (1991)
- [2] 福見, 大松, 竹田, 小坂: ニューラルネットワークによる回転に不変なパターン認識システム, システム制御情報学会研究発表講演会講演論文集, pp.97-98 (1991)
- [3] 福見, 大松, 竹田, 小坂: パターンの回転に不変な認識を行うエッジ検出機構を有するニューラルネットワーク, 電気学会論文誌C分冊, Vol.112, No.8, pp.457-464 (1992)
- [4] 竹田, 大松, 井上, 尾波: ランダムマスクによるニューラルネットワークの規模の縮小化と紙幣識別への応用, システム制御情報学会研究発表講演会講演論文集, pp.555-556 (1992)
- [5] F.Takeda, S.Omatu, and T.Inoue, "Bill Money Recognition by a Small Size Neural Network," Bull.of Fac. of Engineering, Tokushima University, No.38, pp.113-121 (1993)
- [6] 福見, 大松, 竹田, 小坂: 回転に不変なニューラルパターン認識システムとコイン認識への応用, 計測と制御 総合論文 (計測自動制御学会論文誌) (掲載予定)
- [7] F.Takeda and S.Omatu, "Recognition System of US Dollars Using a Neural Network with Random Masks," Proceedings of the International Joint Conference on Neural Networks (1993) (will be appeared)
- [8] F.Takeda and S.Omatu, "High Speed Bill Money Recognition by Neural Networks," IEEE, Trans. on Neural Networks (will be appeared)

謝 辞

本研究を遂行し、まとめるにあたり、始終直接懇切な御指導、御鞭撻、励ましを賜った徳島大学大松繁教授に深く感謝の意を表します。

そして、本論文を完成させるにあたり、有益な御教示を賜った徳島大学木内陽介教授ならびに川上博教授に深く感謝の意を表します。


さらに、本論文において種々の実験に適切なアドバイスを賜った徳島大学福見稔助手、徳島大学富士正人技官、株式会社リライアンス藤田靖部長ならびに琉球大学短期大学部金城寛助手に深く感謝の意を表します。

また、論文の作成において少なからずの御協力を賜ったマレーシア工科大学マルズ・キ・カリド上級講師に心から感謝の意を表します。

加えて、常日頃、励ましの言葉を賜ったグローリー工業株式会社開発部井上卓係長（現開発センターグループリーダー）ならびに四国総合研究所松村茂憲主席研究員に深く感謝の意を表します。

そして、本研究を社内で進めるにおいて絶えず精神的な御援助、御配慮を賜ったグローリー工業株式会社井戸久男専務取締役（研究開発本部本部長）、川内俊補専務取締役（東京本部本部長）に厚く感謝の意を表します。

最後に本研究を進めるにおいて徳島大学博士課程への留学の推薦を頂いた開発部尾波宰三部長（現開発センター所長）、その決裁を頂いたグローリー工業株式会社尾上壽男社長、松下寛治会長に厚く感謝の意を表します。



様式 9

論文審査の結果の要旨

報告番号	甲工 乙工第 24 号 工修	氏名	竹田 史章
審査委員	主査 大 松 繁 副査 川 上 博 副査 木 内 陽 介		
学位論文題目 知的情報処理応用による貨幣識別技術に関する応用			
<p>審査結果の要旨</p> <p>本論文は、知的情報処理による貨幣識別について研究したものである。一般に、紙幣識別機は市場ニーズとして、一秒間に10枚以上の紙幣を識別する能力、さらに、製品としてはハードウェアの低コスト化と装置のコンパクト性が要求されている。したがって、製品化においてはアルゴリズムそのものを演算量の少ない単純なものにすることが必要である。これまでに、紙幣識別機開発の分野では独自の識別式が考案され、この方式による製品化が行われてきた。この識別式は基本的に加算、減算、比較の各演算子を用いて紙幣の特徴を表現したものである。しかしながら、識別式を構成するパラメータに関しては、金種の違い、データ採取時の紙幣の回転、位置ずれ、起伏によるデータ変動を想定して、設計者が決定している。このような方法ではパラメータの組合せ数が非常に多く、得られた組合せが最適であるか否かの保証はなされていなかった。そこで、設計目標に到達したか否かを大量の紙幣データを用いて実験的に検証し、多大な工数を要して識別機の開発が行われてきた。ところで、設計者のノウハウおよび経験である紙幣識別に関する知識は、個々の単発的な処理手続きであり、パラメータ決定を行う際には一貫した処理フローを作成するのが困難である。このような専門家の試行錯誤の分野に知的情報処理手法の一つとして、本研究では、まずエキスパートシステム（以後ESと略記する）を導入している。ここでは、紙幣識別の分</p>			

離関数である識別式決定に対するESの構築について考察し、つぎに、ESを識別技術に導入することにより、従来技術と比較して大幅に開発期間および識別性能の向上が得られることを示している。

しかしながら、ここでのESの効果は、紙幣の識別式決定においてのみ有効であり、紙幣識別における分離関数方式の問題点（市場における紙幣に対する汚れ、破れなどのノイズ、さらにはセンサ系に対する信号ノイズなどのロバスト性の問題）を解決するに至っていなかった。そこで、本研究では紙幣識別分野への知的情報処理の別のアプローチとして、ニューラルネットワーク（以後NNと略記する）を検討している。まず、NNを応用した紙幣識別手法について考察している。とくに、紙幣識別に適したNNの構成ならびに入力情報の検討をフーリエ変換などを利用して行っている。また、紙幣識別の分野で従来から問題となっていた識別結果に対する信頼性に対して、新たに信頼性評価規範を導入し、潜在的な識別性能を検討する。NNを応用した紙幣識別手法が、識別性能と開発期間の点から、従来の分離関数方式や一部のパターンマッチング方式と比較して非常に有効な手法であることを述べている。これらの種々の検討結果を基に、NNを実際の8あるいは16ビットのCPUを有する識別機に移植する場合、ネットワークの規模が大きな問題となっている。そこで本研究では、入力画像の一部を任意に被覆するランダムマスクを提案している。ここでは、このランダムマスクによるNNの規模の縮小化について述べ、本提案手法により入力画像情報を容易に圧縮することが可能であることを示している。さらに、従来のNNを用いた手法と比較して、提案手法が識別性能の劣化を最小限にとどめ、大幅なネットワークの規模の縮小化を可能とすることを定量的に示している。また、提案手法により特殊なデバイスを用いなくても実システムが容易に構築可能であることを既存の識別機とパーソナルコンピュータを用いて具体的に示している。

最後に、実験システムにより、日本、韓国、米国の複数国紙幣が混合した場合の紙幣識別が可能であることを実験的に検証している。

以上本研究は、知的情報処理応用による貨幣識別技術に関する応用であり、本論文は博士（工学）の学位授与に値するものと判定する。